

Von der Fakultät für Verkehrswissenschaften „Friedrich List“
der Technischen Universität Dresden
zur Erlangung des akademischen Grades
Doktoringenieur (Dr.-Ing.)
genehmigte Dissertation

**Ein Beitrag zur Identifikation von
Bewegungszuständen mittels Inertialsensorik
für die Stützung von Navigationsfunktionen
im Öffentlichen Personenverkehr**

eingereicht von Dipl.-Ing. Ina Partzsch
geb. Seydel am 23. Februar 1985 in Dresden

1. Gutachter: Prof. Dr.-Ing. Oliver Michler
2. Gutachter: Prof. Dr.-Ing. Günter Löffler

Tag der Abgabe: 1.12.2017

Tag der Verteidigung: 18.2.2019

Danksagung

Etwa viereinhalb Jahre begleitete mich das Thema der Bewegungszustandsidentifikation. Die Arbeiten dazu münden nun in der vorgelegten Dissertationsschrift.

Mein Dank gilt Prof. Dr.-Ing. Oliver Michler für die fachliche Betreuung als verantwortlicher Hochschullehrer, sowie Prof. Dr.-Ing. Günter Löffler für die Übernahme des Zweitgutachtens.

Darüber hinaus danke ich insbesondere Prof. Dr.-Ing. Matthias Klingner für die Möglichkeit zur Promotion und die fachlichen Anregungen.

Für die fachliche Diskussion und kritische Durchsicht von Vorversionen dieser Arbeit danke ich besonders Dr.-Ing. Georg Förster, sowie Dr.-Ing. Johannes Partzsch, Dr.-Ing. Daniel Haufe und Dr.-Ing. Erhard Seydel sowie Dipl.-Ing. (FH) Monika Keil.

Die durchgeführten Versuche wären nicht möglich gewesen ohne das SMART-WAY-Konsortium (Initiale Idee zur Bewegungszustandsidentifikation), das Messstraßenbahn-Konsortium, namentlich Dipl.-Ing. Gunther Dürrschmidt (Bereitstellung der Messstraßenbahndaten als Fahrzeugreferenz), das CPTI-Projektkonsortium (Messplattform deRFnode, Messdaten für den Anfahrtruck), Dipl.-Ing. Hans-Georg Engler (Protokollant der Messstraßenbahn-Fahrt), Dipl.-Rest. (FH) Beatrice Böhm (Testperson Laufversuch) und Dipl.-Ing. (FH) Christoph Barz (Busfahrer für Anfahrtruck-Versuch).

Für den Laboraufbau zur Schwingungsreproduktion danke ich Dipl.-Ing. (FH) Bert Eltzschig, M.Sc. Andre Heidrich und Dipl.-Ing. Florian Gierisch.

Ein ganz herzliches Dankeschön möchte ich zuletzt an alle Kolleginnen und Kollegen am Fraunhofer-Institut für Verkehrs- und Infrastruktursysteme IVI und an der Professur „Informationstechnik für Verkehrssysteme“ der Technischen Universität Dresden während der Entstehung dieser Arbeit für Unterstützung und Motivation richten. Das Doktorandenseminar unter der Leitung von Prof. Dr.-Ing. Stephan Zipser sowie der OIK/ITVS-Doktorandenstammtisch gaben maßgebliche Impulse zu dieser Arbeit.

Inhalt

ABKÜRZUNGSVERZEICHNIS	VII
------------------------------------	------------

SYMBOLVERZEICHNIS	VIII
--------------------------------	-------------

1 EINLEITUNG	1
---------------------------	----------

2 GRUNDLAGEN DER IDENTIFIKATION VON BEWEGUNGSZUSTÄNDEN	4
---	----------

2.1 Stand der Technik	4
------------------------------------	----------

2.1.1 Nutzung einer mobilen Messplattform	4
---	---

2.1.2 Nutzung einer fahrzeug- oder infrastrukturseitigen Messung	5
--	---

2.1.3 Überlagerung von Bewegungen	5
---	---

2.2 Begriffe der Dynamik	6
---------------------------------------	----------

2.2.1 Koordinatensysteme	6
--------------------------------	---

2.2.2 Beschreibung von Bewegungen	8
---	---

2.2.3 Fahrzeugschwingungen	10
----------------------------------	----

2.2.4 Der Mensch als Schwingungskoppler und Schwingungsquelle	13
---	----

2.2.5 Erzeugung von Schwingungen im Labor	15
---	----

2.3 Beschleunigungsmessung	15
---	-----------

2.3.1 Rechnergestütztes Messen	15
--------------------------------------	----

2.3.2 Kriterien zur Auswahl eines Beschleunigungsmessers	17
--	----

2.3.3 Prinzipien der Beschleunigungsmessung	17
---	----

2.3.4 Betrachtungen zur Messunsicherheit	19
--	----

2.3.5 Entwurfsanforderungen an den Messaufbau	21
---	----

2.4 Zustandsmodelle menschlicher Bewegungsformen	21
---	-----------

2.4.1 Stochastische Prozesse und Ketten	21
---	----

2.4.2 Anwendung auf Bewegungszustände	22
---	----

2.5 Signalanalyse	23
--------------------------------	-----------

2.5.1 Überblick zu Analysedomänen	23
---	----

2.5.2 Signalanalyse im Zeitbereich	24
--	----

2.5.3 Signalanalyse im Frequenzbereich: Fourier- und Wavelet-Analyse	25
--	----

2.5.4 Signalkorrelation	26
-------------------------------	----

2.6 Signalklassifikation zur Zustandserkennung	27
---	-----------

2.6.1 Generelle Herangehensweise	27
--	----

2.6.2	Vorverarbeitung	28
2.6.3	Merkmalsextraktion und -verdichtung.....	29
2.6.4	Klassifikation	29
2.6.5	Hidden Markov Model-Filterung	32
2.6.6	Test und Bewertung von Klassifikatoren	33
2.7	Beitrag der vorliegenden Arbeit	34
3	EIN NEUES VERFAHREN ZUR BEWEGUNGSKLASSIFIKATION.....	36
3.1	Begriffsdefinitionen.....	36
3.2	Systemperspektiven.....	37
3.2.1	Physikalische Betrachtung.....	37
3.2.2	Messtechnische Betrachtung	40
3.3	Zustandsmodelle	42
3.3.1	Geschichtetes Zustandsmodell	42
3.3.2	Bewegungsmodi und -zustände	43
3.4	Klassifikatorentwurf	48
3.4.1	Systemübersicht	49
3.4.2	Vorverarbeitung	50
3.4.3	Klassifikation	50
4	EMPIRISCHE UNTERSUCHUNGEN ZUR BEWEGUNGSKLASSIFIKATION	55
4.1	Versuchsrandbedingungen	55
4.1.1	Untersuchungsziele	55
4.1.2	Verwendete Messsysteme.....	56
4.1.3	Durchführung der Messkampagnen.....	57
4.2	Versuch 1: Schätzung des Bewegungszustandes eines Fahrzeugs	60
4.2.1	Erwartete Charakteristika der Fahrzeugbewegungszustände.....	60
4.2.2	Signalanalyse der Messstraßenbahndaten	61
4.2.3	Signalanalyse der Straßenbahn-deRFnode-Daten.....	65
4.2.4	Vergleich der Messstraßenbahndaten mit deRFnode-Daten.....	67
4.2.5	Signalanalyse der Bus-deRFnode-Daten.....	69
4.2.6	Ableitung des heuristischen Entscheidungsbaums.....	71
4.2.7	Diskussion der Transmissions- und Emissionsmatrix zur HMM-Filterung.....	73
4.2.8	Ermittlung des Trainingsfehlers.....	74
4.2.9	Ermittlung des Generalisierungsfehlers.....	76

4.3 Versuch 2: Schätzung des Bewegungszustandes einer Person	78
4.3.1 Theoretische Charakteristika der Personenbewegungszustände	78
4.3.2 Signalanalyse	79
4.3.3 Ermittlung des Trainingsfehlers	81
4.3.4 Ermittlung des Generalisierungsfehlers	82
4.4 Versuch 3: Schätzung des Bewegungsmodus	83
4.4.1 Geschichtetes Vorgehen zur Identifikation von Bewegungsmodus und Bewegungszustand	83
4.4.2 Theoretische Charakteristika der Bewegungsmodi	83
4.4.3 Signalanalyse	84
4.4.4 Ermittlung des Trainingsfehlers	87
4.4.5 Ermittlung des Generalisierungsfehlers	88
4.5 Schlussfolgerungen zur Identifizierbarkeit von Bewegungszuständen	89
 5 REPRODUKTION VON BEWEGUNGEN IN EINER LABORUMGEBUNG	 92
5.1 Location Based Services in-the-loop	92
5.2 Laborkonzept zur Reproduktion von Bewegungsmustern	93
5.3 Übertragungseigenschaften des Systems	95
5.3.1 Vorversuche mit Sinussignalen	95
5.3.2 Reale Signale	96
5.4 Reproduktion von Klassifikatorentscheidungen	97
5.4.1 Signalanalyse	97
5.4.2 Aufbau eines Entscheidungsbaums	98
5.4.3 Trainings- und Generalisierungsfehler	99
 6 ANWENDUNG VON BEWEGUNGSMUSTERKLASSIFIKATOREN IN STANDORTBEZOGENEN DIENSTEN DES ÖPV	 101
6.1 Bewegungszustandsklassifikation für ÖPV-Navigationssysteme	101
6.2 Bewegungszustandsklassifikation zur automatischen Fahrgasterfassung	104
 7 ZUSAMMENFASSUNG	 108
7.1 Zusammenfassung und Bewertung der Ergebnisse	108
7.2 Methodenkritik	109
7.2.1 Datenherkunft	109

7.2.2	Analysedatensätze	109
7.2.3	Eignung der Verfahrensweise.....	110
7.3	Anwendungsempfehlungen	110
GLOSSAR		112
LITERATURVERZEICHNIS		114
ANHANG		125
Anhang A Zustandsmodelle für Straßenbahn		125
Anhang B Wahrscheinlichkeitsbasierte Klassifikatorwirksamkeitsbetrachtung		127
Anhang C Sensoreigenschaften		129
Anhang D Boxplots zur Analyse der Messstraßenbahndaten		130
Anhang E Boxplots zur Analyse der deRFnode-Daten in der Straßenbahn		136
Anhang F Boxplots zur Analyse der deRFnode-Daten im Bus.....		142
Anhang G Boxplots zur Analyse der deRFnode-Daten bei Personenbewegung		148
Anhang H Boxplots zur Analyse des Bewegungsmodus auf Basis der deRFnode-Daten.....		154

Abkürzungsverzeichnis

Bus	engl. binary unit system
CAN	engl. controller area network
CPTI	engl. Cool Public Transport Information
csv	engl. comma separated value
DTW	engl. dynamic time warping
DTWT	engl. discrete time wavelet transform
ENOB	engl. effective number of bits
FFT	engl. fast Fourier transform
GNSS	engl. global navigation satellite system
GPS	engl. global positioning system
HMM	engl. hidden Markov model
INS	Inertialsensorik
IVS	intelligentes Verkehrssystem
ITVS	Informationstechnik für Verkehrssysteme
LBS	engl. location based service
MEMS	engl. micro electrical micro mechanical system
ÖPV	Öffentlicher Personenverkehr
PKW	Personenkraftwagen
RMS	engl. root mean square
ROC	engl. receiver operating characteristic
Strab	Straßenbahn
STFT	engl. short time Fourier transform
WLAN	engl. wireless local area network
WSN	engl. wireless sensor network

Symbolverzeichnis

A	Matrix der Übergangswahrscheinlichkeiten mit den Elementen A_{ij}
a_x, a_y, a_z	Beschleunigungen in x, y, z -Richtung eines Koordinatensystems
a_0, a_1, a_i	Fourierkoeffizienten
B	Matrix der Übergangswahrscheinlichkeiten mit den Elementen B_{ij}
c	Federkonstante
d	Dämpfungskonstante
e	Zähler der Anzahl existierender Entscheidungsklassen
k, i, j, n	Zählindex
K	Anzahl Klassen (Label, Entscheidungen) zur Klassifikation
\mathbf{K}_i	i -te Kovarianzmatrix
m	Masse
m_f	Mittelwert
N	Wortbreite
\mathcal{N}	Normalverteilung
p	Wahrscheinlichkeitsdichte
P	Wahrscheinlichkeit
s	Skalierungsfaktor der Anregung mit Einheit Kraft · Zeit
\mathbb{S}	Symbol
S/R	Signal/Rausch-Verhältnis
$R_f(\tau)$	Korrelationsfunktion
T	Parameterraum der Zeit
T_P	Periodendauer
t	Zeit
t_k	Zeitpunkt
v	Element der Verwechslungsmatrix
\mathbf{V}	Verwechslungsmatrix
\mathbf{x}	Merkmalsvektor aus mehreren Zufallsgrößen X
x^e, y^e, z^e	Koordinaten im erdfesten Koordinatensystem
x^f, y^f, z^f	Koordinaten im Fahrzeug-Koordinatensystem

X	Zufallsgröße
$\mathbf{z}(t)$	Zustand zum Zeitpunkt t
Z	Zustandsraum
δ	Dämpfungsmaß
μ	Mittelwert
σ	Streuung
τ	Korrelationszeit
$\omega,$	Kreisfrequenz
ω_0	Kennkreisfrequenz

1 Einleitung

Die zuverlässige Ortung von Fahrgästen und Fahrzeugen bildet die Grundlage für Anwendungen im Öffentlichen Personenverkehr (ÖPV) im Rahmen intelligenter Verkehrssysteme (IVS). Geeignete Basistechnologien sind Globale Satellitennavigationssysteme (engl. global navigation satellite systems, GNSS) oder andere funkbasierte Ansätze, wie beispielsweise wireless area networks (WLAN) oder wireless sensor networks (WSN). Inertialsensoren können diese Technologien unterstützen.

Dies ist notwendig, da bezogen auf den GNSS-Signalempfang schwierige urbane Anwendungsszenarien existieren, wie zum Beispiel Häuserschluchten (Mehrwegeausbreitung und Reflexionen durch Gebäude) und Tunnel (Abschattung). Die ÖPV-Fahrzeugumgebung stellt mit metallisierten Fenstern oder zusätzlicher Signaldämpfung durch hohes Passagieraufkommen ebenfalls eine Herausforderung für die GNSS-basierte Ortung dar.

Daten von Inertialsensoren (Beschleunigungssensoren, Drehratensensoren) sind eine mögliche weitere Ortungsinformationsquelle, da diese die aktuelle Bewegung des Sensors abbilden. Im Rahmen dieser Arbeit werden Beschleunigungssignale ausgewertet und auf ihr Unterstützungspotential untersucht. Diese Beschleunigungssignale geben Aufschluss über die Bewegung der eingesetzten Sensorplattformen und gegebenenfalls deren Umgebung (tragende Person, verwendetes Fahrzeug). Ein wesentlicher Gegenstand dieser Arbeit ist der vertiefte Vergleich von theoretisch vorhandenen und praktisch messbaren Fahrzeugsignalen mit den durch die nutzende Person beeinflussten Signalen einer mobilen Sensorplattform (zum Beispiel Smartphone, entsprechend ausgestattetes Nutzermedium). Darauf aufbauend wird ein neues Verfahren zur Schätzung von Bewegungsmodus (d.h. Verkehrsmittelwahl) und -zustand (detaillierte Bewegungsform, z. B. Kurvenfahrt) entwickelt und anhand von Beispielmessungen auf seine Anwendbarkeit hin untersucht. Diese Information kann anschließend zur Stützung von Navigationsfunktionen im ÖPV verwendet werden.

Diese Arbeit beantwortet die Fragestellung, ob mit geeignet verarbeiteten Sensorwerten einer mobilen Sensorplattform (z. B. Smartphone) auf den Bewegungszustand eines Fahrzeuges geschlossen werden kann.

Der Beitrag dieser Arbeit liegt zusammengefasst in den folgenden Punkten:

- Beschreibung von geeigneten Messsystemen zur Erfassung von Beschleunigungen und damit von Personen- und Fahrzeugbewegungen,
- Analyse von Bewegungszuständen, die mit solchen Messsystemen erfasst werden,
- Entwurf und Umsetzung eines geeigneten Algorithmus zur Bewegungszustandserkennung und der Nutzung dieser Information zur Lokalisierung von Fahrzeugen und Passagieren, sowie
- Integration der Erkenntnisse in ein Laborkonzept zum Test standortbezogener Dienste (engl. Location Based Services, LBS).

Die Arbeit zeigt damit eine Möglichkeit zur Nutzung von Beschleunigungssignalen als zusätzliche Ortungsinformation auf. Die Reproduktion dieser Beschleunigungssignale in der Laborumgebung der Professur „Informationstechnik für Verkehrssysteme“ (ITVS) an der TU Dresden wird umgesetzt und diskutiert. Die Laborumgebung hat das Ziel der originalgetreuen Wiederholung von Messfahrten zu Sensor- und Softwaretests für die Ortung von Verkehrsteilnehmern und deren Kommunikation.

Die Arbeit ist wie folgt gegliedert: Im Kapitel 2 werden die physikalischen, stochastischen und signalanalytischen Grundlagen für die Klassifikation von Bewegungszuständen gelegt. Den Abschluss des Kapitels bildet die Ableitung der im Rahmen dieser Arbeit zu bearbeitenden offenen Forschungsfragen. Auf Basis dieser Grundlagen wird im Kapitel 3 ein geeignetes Verfahren zur Bewegungsklassifikation entworfen und im Kapitel 4 werden empirische Untersuchungen auf Basis exemplarischer Messreihen aus dem ÖPV durchgeführt. Signalanalyse und -klassifikation von Bewegungsmustern von Fahrzeugen (Unterkapitel 4.2) und Personen (Unterkapitel 4.3) sowie zur Modusentscheidung (Unterkapitel 4.4) stehen im Vordergrund. Hierzu werden beispielhaft Klassifikatorvarianten aufgezeigt und deren Leistungsfähigkeit in verschiedenen Testszenarien hinsichtlich der Klassifikationsgüte diskutiert.

Kapitel 5 befasst sich mit der Reproduktion von Bewegungen in der ITVS-Laborumgebung zur Wiedergabe von Messfahrten im Ortungskontext. Diese Umgebung kann genutzt werden, um standortbezogene Dienste zu testen, die in der ÖPV-Umgebung auf Bewegungssignale reagieren. Hierzu wird das Konzept „Location Based Services in-the-loop“ im Unterkapitel 5.1 vorgestellt und im Unterkapitel 5.2 für Bewegungsmuster konkretisiert. Unterkapitel 5.3 diskutiert die Reproduktionsgüte für konkrete Bewegungsmuster.

Die Übertragung der Erkenntnisse aus Kapitel 4 und 5 in den Anwendungskontext wissenschaftlicher Projekte im Bereich standortbezogener Dienste im ÖPV erfolgt im Kapitel 6. Anhand von Beispielprojekten zu ÖPV-Navigationssystemen im Unterkapitel 6.1 und automatischer Fahrgasterfassung im Unterkapitel 6.2 wird gezeigt, wie Bewegungsmuster genutzt werden können.

Im Kapitel 7 folgen eine Zusammenfassung und Bewertung der Ergebnisse der Arbeit, eine kritische Betrachtung der verwendeten Methoden sowie abschließende Anwendungsempfehlungen.

2 Grundlagen der Identifikation von Bewegungszuständen

In diesem Kapitel werden die Grundlagen der Identifikation von Bewegungszuständen vorgestellt.

Anhand des aktuellen Stands der Technik kann gezeigt werden, dass bisherige Untersuchungen Teilaspekte einer solchen Bewegungsmusterklassifikation betrachtet haben. Für eine holistische Sicht ab Signalentstehung am Fahrzeug über die Signalaufnahme mit mobilen Sensoren bis zur Signalreproduktion im Labor werden in diesem Kapitel physikalische Grundlagen der Dynamik und Zustandsmodellierung von bewegten Objekten sowie messtechnische Grundlagen zur Beschleunigungsmessung dargestellt. Anschließend werden gängige Methoden der Signalanalyse aufgezeigt. Es folgt eine Übersicht zur Signalklassifikation für die Mustererkennung in Bewegungsmessungen. Den Abschluss des Kapitels bildet eine Diskussion zur Neuartigkeit der Beiträge dieser Arbeit.

2.1 Stand der Technik

In diesem Abschnitt wird der aktuelle Stand der Technik zu den in der Arbeit diskutierten Fragestellungen dargestellt. Dies betrifft zum einen die Datengrundlage und das anhand dieser Daten analysierte System sowie zum anderen das jeweils verwendete Bewegungsanalyseverfahren.

2.1.1 Nutzung einer mobilen Messplattform

Es existiert eine Vielzahl an Anwendungen, die Beschleunigungsdaten auswerten und nutzen:

- medizinische Fragestellungen:

Medizinische Fragestellungen (Überprüfung des Ganges, Sturzprävention [Dai et al. 2010]) führten zur Arbeit mit speziellen Messplattformen. Mittlerweile werden hier Smartphones eingesetzt [Mathie et al. 2004, Preece et al. 2009, Figo et al. 2010].

- Erhebung von Verkehrskenngrößen:

Wie Partzsch et al. (2012) dargelegen, beschäftigen sich, motiviert durch die wachsende Markverbreitung von Smartphones, verschiedene Forschungsgruppen mit der Frage, wie aus den Smartphone-Sensordaten Informationen über die Art und Weise der Fortbewegung der nutzenden Person geschlossen werden kann. Kwapisz et al. (2010) und Frank et al. (2010) untersuchen die Muster menschlicher Bewegungsformen.

Yang (2009) und Sun et al. (2010) schlossen, wenngleich undifferenziert, die motorisierte Bewegung mit ein, wohingegen Wang et al. (2010) und Yang et al. (2010) prinzipiell den Typ der motorisierten Bewegung unterschieden. Allen genannten Untersuchungen ist gemein, dass sie im Bewegungsmodus (z. B. Person läuft oder fährt einen PKW), nicht im Bewegungszustand (z. B. sitzt in einem PKW, der gerade um eine Kurve fährt) differenzieren. Ausnahmen bilden hier Detektion von Notbremsungen [Thompson et al. 2010]. Alle anderen in der Literaturrecherche gefundenen Arbeiten zur Verkehrsmitteldetektion, die die motorisierte Form mit weiteren Modi unterscheiden, nutzen zusätzliche Sensoren und Informationen über das Nutzerverhalten, z. B. [Stenneth et al. 2011, Kohla 2013], wie z. B. GPS.

2.1.2 Nutzung einer fahrzeug- oder infrastrukturseitigen Messung

Der Messung einer menschlichen Bewegung mittels Sensorplattform an einer Person steht eine fahrzeug- oder infrastrukturseitige Messung gegenüber. Zur Bewegungsanalyse von Fahrzeugen existieren Arbeiten zur Nutzung von Fahrzeugsignalen für die Fahrzeugdiagnose [Heirich et al. 2011], oder zur Fahrer und Fahrstilerkennung, zum Beispiel [Van Ly et al. 2013, Karaduman et al. 2013]. Mamar et al. (2008) untersuchten die Nutzung von Infrastruktursignalen. Dabei wurden Vibrationen an der Schiene zur Defekterkennung gemessen.

Der direkte Vergleich zwischen einer Messung mittels mobiler Sensorplattform und einer fahrzeug- oder infrastrukturbasierten Messung wurde bei der Recherche zu dieser Arbeit nicht gefunden. Johnson et al. (2011) zeigen die Kombination von Fahrzeug- und Smartphone-Messungen. In diesem Fall werden im PKW CAN-Bus (engl. controller area network binary unit system)-Signale als Referenz genutzt, jedoch nicht tiefgreifend analysiert.

2.1.3 Überlagerung von Bewegungen

Die in dieser Arbeit diskutierte Überlagerung von Bewegungen verschiedener Objekte (Menschen, Sensorplattform, Fahrzeug) ist aktuell nicht Gegenstand allgemein zugänglicher Quellen. Widhalm et al. (2012) sprechen zwar die Überlagerung von menschlichen Bewegungen und Fahrzeugbewegungen als mögliche Fehlerquelle für Fehlklassifizierungen an, analysieren dies aber nicht weiter. Von anderen Autoren wird der Einfluss der Sensorplattformposition auf die Klassifikationsgüte eines anderen Prozesses untersucht, nicht die Position klassifiziert. [Alanezi et al. 2013, Lester et al. 2006]

Gemäß der im Rahmen dieser Arbeit durchgeführten Literaturrecherche lag der Schwerpunkt der wissenschaftlichen Veröffentlichungen auf der automatisierten Klassifizierung von Bewegungsda-

ten mobiler Endgeräte (Smartphones, medizinische Sensorik). Diese Arbeit analysiert nun darüberhinausgehend vergleichend Bewegungsdaten von Fahrzeugen und von mobilen Endgeräten, sowie labortechnisch generierter Bewegungszuständen. Die zum Verständnis notwendigen Grundlagen der Beschreibung und Messung von Bewegungen sowie deren Modellierung, Signalanalyse und Klassifikation werden in den nächsten Unterkapiteln vorgestellt.

2.2 Begriffe der Dynamik

Dieser Abschnitt fasst wesentliche Grundlagen aus der Dynamik zusammen, die notwendig sind, um bewegte Körper zu beschreiben. Dazu ist die Betrachtung von Koordinatensystemen nötig, in denen die Beschreibung einer Bewegung erst ermöglicht wird. Diese allgemeine Betrachtung wird anschließend auf Schwingungen von und in Fahrzeugen sowie Personen übertragen. Den Abschluss bildet ein Abschnitt über die künstliche Erzeugung von Schwingungen.

2.2.1 Koordinatensysteme

Für die Identifikation von Bewegungszuständen muss definiert sein, wie eine Bewegung beschrieben werden kann. Grundlage bildet dafür ein Koordinatensystem, mit dem eindeutig Punkte in einem geometrischen Raum definiert werden können.

Dazu sind sechs Koordinatenangaben zu definieren, die dem Freiheitsgrad 6 eines starren Körpers entspricht [Demtröder 2008]:

- drei Ortskoordinaten zur Beschreibung der allgemein krummlinigen Bewegung (Translation) des Schwerpunktes,
- drei Winkelkoordinaten zur Beschreibung einer Drehbewegung (Rotation) des Körpers um seine Körperachsen.

Eine Bewegung ist damit als Orts- und/oder Winkelveränderung in diesem Koordinatensystem zu definieren. Sie wird mit Hilfe einer Funktion beschrieben, die den Verlauf der sechs veränderlichen Koordinatenangaben über die Zeit angibt.

Für den Körperschwerpunkt lassen sich folgende Vektoren aufstellen:

- der Ortsvektor $\mathbf{r}(t) = [x \ y \ z]^T$, der zeitlich veränderlich eine Bahnkurve beschreibt,
- der Geschwindigkeitsvektor $\mathbf{v} = d\mathbf{r}(t)/dt$, der angibt, welche Ortsänderung auf der Bahnkurve pro Zeit realisiert wird,
- der Beschleunigungsvektor $\mathbf{a} = d\mathbf{v}(t)/dt$, der die Geschwindigkeitsänderung pro Zeit beschreibt. Dieser ist zusammengesetzt aus Bahn- und Normalbeschleunigung.

Es gibt verschiedene Koordinatensysteme. Zunächst sei das Inertialsystem diskutiert. In einem solchen Koordinatensystem gelten die drei Newtonschen Axiome (Trägheitsprinzip, Aktionsprinzip und Reaktionsprinzip [Newton 1687]). Jedes Koordinatensystem, das sich mit konstanter Geschwindigkeit gegen ein Inertialsystem bewegt, ist ebenfalls ein Inertialsystem [Demtröder 2008].

Weitere wesentliche Koordinatensysteme sind:

- Das erdfeste Koordinatensystem (earth centered, earth fixed), siehe Abbildung 1, links: Der Ursprung des Koordinatensystems befindet sich im Mittelpunkt des als Rotationsellipsoid angenäherten Planeten Erde. Die x^e -Achse wird bestimmt durch die Schnittgerade von Äquatorebene und der Ebene des Nullmeridians [Wendel 2007]. Ein solches Bezugssystem ist strenggenommen kein Inertialsystem, da sich die Erde auf einer elliptischen Bahn um die Sonne bewegt und das Geozentrum eine Beschleunigung erfährt. Allerdings sind die Beschleunigungen für den hier betrachteten Fall vernachlässigbar gering. Das System wird daher Quasi-Inertialsystem genannt [Mansfeld 2004, S. 31], die Newtonschen Axiome gelten in für diese Betrachtungen ausreichender Näherung.
- Das körperfeste Koordinatensystem: Der Ursprung eines solchen Systems befindet sich in einem Körper, beispielsweise
 - in einem Fahrzeug, siehe Abbildung 1, Mitte: die Achsen sind dann fest in Bezug zum Fahrzeug und weisen in Fahrtrichtung (x^f), in Fahrzeugquerrichtung nach rechts (y^f) und in Richtung Fahrzeugboden (z^f),
 - in einer Sensorplattform, siehe Abbildung 1, rechts: die Achsen sind dann fest in Bezug zur Plattform und weisen, zum Beispiel für Android-Smartphones im Hochformat in dessen Querrichtung (x^p), nach oben (y^p) und senkrecht aus dem Gerät heraus (z^p).




Abbildung 1: Verschiedene Koordinatensysteme: Erdfestes Koordinatensystem und Körperkoordinatensysteme (in Anlehnung an Partzsch et al. (2013b))

2.2.2 Beschreibung von Bewegungen

Die in dieser Arbeit diskutierte Bewegungszustandsidentifikation basiert auf einer Bewegungssignalanalyse. Um zu erwartende Signalformen abschätzen zu können, werden in diesem Abschnitt typische Bewegungen – allgemein und in Form von Schwingungen – sowie deren abstrakte Signalform zusammengefasst.

2.2.2.1 Bewegungsänderungen

Wie Newton (1687) beschrieb, bewirkt eine Kraft eine zu ihr proportionale Bewegungsänderung. Sie wird entlang der Krafteinleitungslinie realisiert [Wolfers (1872)]. Die Gleichung für die Kraft \mathbf{F}

$$\mathbf{F} = m \mathbf{a} \quad (1)$$

aus dem Produkt einer Masse m und einer Beschleunigung \mathbf{a} geht auf Euler (1752) zurück. Kräfte stehen somit im direkten Zusammenhang mit Beschleunigungen. Die Messung von Beschleunigungen und die darauf aufbauende Signalanalyse und Klassifikation zur Bewegungszustandsidentifikation im ÖPV-Kontext ist Kern dieser Arbeit.

2.2.2.2 Schwingungen

Schwingungen sind zeitlich periodische Bewegungsänderungen. Sie entstehen in mechanischen Systemen, wenn eine Störung des Systemgleichgewichts Kräfte erzeugt, die der Ursache der Störung entgegenwirken [Franke 1969]. Hier treten also periodisch zeitlich veränderliche Beschleunigungen auf.

Reale mechanische schwingungsfähige Systeme bestehen im Allgemeinen aus einem Element zur Speicherung potentieller Energie (Feder), einem Element zur Speicherung kinetischer Energie (Masse) und einem Element, das die kinetische Energie durch Reibungskräfte in thermische Kräfte umwandelt (Dämpfer).




Abbildung 2: Elemente eines schwingungsfähigen mechanischen Systems

Folgende Kräfte können in einem solchen System je nach Zusammenstellung der Komponenten wirken:

- $F_A = m a$ Trägheitskraft, beschrieben durch das Aktionsprinzip,
- $F_F = c \Delta r$ Federkraft, beschrieben durch das Hooke'sches Gesetz mit der Federkonstante c und der Auslenkung Δr , basierend auf dem Ortsvektor $\mathbf{r}(t)$: $\Delta \mathbf{r} = \mathbf{r}(t_2) - \mathbf{r}(t_1)$, sowie
- $F_D = d \dot{v}$ Reibkraft, beschrieben durch das Dämpfungsgesetz mit der Dämpfungskonstanten d .

Die Kreisfrequenz der Federschwingung wird mit

$$\omega_0^2 = c/m \quad (2)$$

definiert.

Existiert im System ein Dämpfer, wird in das Kräftegleichgewicht die Reibkraft F_D eingebracht. Dazu wird das Dämpfungsmaß δ mit $\delta = d/(2m)$ eingeführt. Die Differentialgleichung für die Beschreibung einer Bewegung im Fall einer freien, gedämpften Schwingung lautet

$$\mathbf{r}'' + 2\delta \mathbf{r}' + \omega_0^2 \mathbf{r} = 0. \quad (3)$$

Es kann gezeigt werden, dass eine solche Schwingung eine verringerte Kreisfrequenz $\omega = \sqrt{\omega_0^2 - \delta^2}$ besitzt [Demtröder 2008].

Neben der Unterscheidung nach Vorhandensein eines Dämpfers in ungedämpfte oder gedämpfte Schwingungen können Schwingungen nach Existenz einer äußeren Kraft in freie oder erzwungene Schwingungen eingeteilt werden.




Abbildung 3: Kräfte in einem gedämpften, eindimensionalen Schwingungssystem mit erzwungener Schwingung

Im Fall der erzwungenen Schwingung wird in die Kräftebeziehung eine externe Kraft \mathbf{F}_E eingebracht. Die allgemeine Differentialgleichung für eine erzwungene, gedämpfte Schwingung lautet daher

$$\mathbf{r}'' + 2\delta\mathbf{r}' + \omega_0^2 \mathbf{r} = \mathbf{F}_E(t). \quad (4)$$

Für den Spezialfall eines periodischen Anregungsausschlags $x(t) = \hat{x} \sin(\omega_E t)$ mit der Amplitude \hat{x} und der Kreisfrequenz ω_E kann gezeigt werden [Eichler (2004)], dass die Lösung der Schwingungsgleichung die Form

$$y = \hat{y} \sin(\omega t - \varphi) \quad (5)$$

mit der Amplitude \hat{y} der resultierenden Schwingung und der Phasenverschiebung φ besitzt.

Es kann weiter gezeigt werden, dass die Frequenz einer erzwungenen Schwingung ω von der Amplitude der äußeren Kraft \mathbf{F}_E , der Dämpfung δ , der Frequenz der Erregerschwingung ω_E und der Eigenfrequenz des erregten Systems ω_0 abhängig ist.

Bei einem solchen Schwingungsvorgang kann ein System mehreren, sich überlagernden Schwingungen ausgesetzt sein. Hierbei gilt das Superpositionsprinzip nach Newton, also die vektorielle Überlagerung der Anteile [Recknagel 1979].

Die Bedeutung von erzwungenen Schwingungen wird bei der Betrachtung einer Fahrzeugumgebung deutlich.

2.2.3 Fahrzeugschwingungen

Die Bewegung eines Sensors in einer ÖPV-Umgebung ist maßgeblich durch Fahrzeugschwingungen ab einer Entstehungsursache und deren Dämpfung oder Verstärkung über einen Übertragungsweg charakterisiert. Dieser Abschnitt befasst sich mit Fahrzeugschwingungen. Die Darstellungen basieren auf den eigenen Veröffentlichungen [Partzsch et al. 2012] und [Partzsch et al. 2013b].

Seit den 1930er Jahren werden in Deutschland Fahrzeugschwingungen mit den Forschungsschwerpunkten Fahrsicherheit und Fahrzeugkomfort untersucht [Mitschke 1962]. Es existieren Standardwerke zu diesem Thema, z. B. [Mitschke 1997], [Willumeit 1998] und [Schramm 2010].

Je nach Zielstellung der Modellierung kann die Dynamik eines Fahrzeugs mit unterschiedlicher Detailtiefe beschrieben werden, z. B. in dem nur eine Schwingungsebene in einem bezogen auf die x^f - ξ^f -Ebene und die y^f - ξ^f -Ebene als symmetrisch angenommenen Fahrzeugmodells betrachtet wird.

Mit Mehrkörpermodellen werden für die Schwingung wesentliche Elemente, d.h. Massen, Dämpfer und Federn dargestellt. Darüberhinausgehend ist eine beliebige Erhöhung des Detailgrades durch Verfeinerung des Mehrkörpermodells bis hin zur Kopplung mit der Finite-Elemente-Methode möglich [Schramm 2010].

Die nachfolgenden Überlegungen basieren auf Mehrkörpermodellen. Solche Modelle bilden ein technisches System mit Hilfe von starren, massebehafteten Körpern nach, die durch masselose Federn, Dämpfer, Lager oder Stellmotoren untereinander und mit der Umgebung verbunden sind. Mathematisch werden diese Modelle, wie im vorangegangenen Abschnitt für einzelne Elemente gezeigt, mittels gewöhnlicher Differentialgleichungen beschrieben, die die Massen-, Dämpfungs- und Federwirkungen, sowie die Erregerkräfte modellieren. [Popp et al. 1993]

Wie Partzsch et al. (2013d) diskutiert, kann für jeden Fahrzeugtyp (z. B. Bus, Straßenbahn) ein spezielles Schwingungsersatzsystem modelliert werden. Abbildung 4 zeigt ein Mehrkörpersystem für einen Linienbus (links) und für eine Straßenbahn (rechts), jeweils samt Fahrpersonal und -gästen. Hierbei wurde eine Symmetrie bezogen auf die x^f - z^f -Ebene angenommen. Die auf einer Grafik von Pütz (2012) basierende Abbildung kann nun mit Hilfe eines von Mitschke (1962) dargestellten Modells für ein Drehgestell einer Straßenbahn in ein Mehrkörpermodell für eine Straßenbahn umgewandelt werden. Drehgelenke bleiben hier für beide Fahrzeugtypen unbeachtet. Auf die detaillierte Modellierung der Personen wird im nächsten Abschnitt eingegangen.

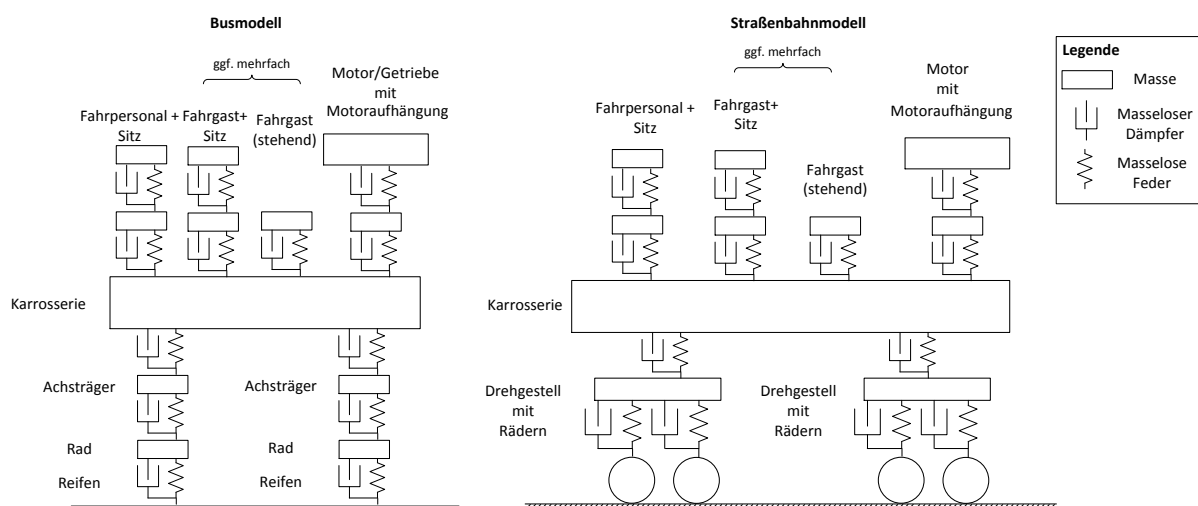


Abbildung 4: Mehrkörpermodelle für Bus (links) und Straßenbahn (rechts) mit je zwei Radachsen oder Drehgestellen (in Anlehnung an Pütz (2012) und Mitschke (1962))

Die in einem solchen Fahrzeug auftretenden Beschleunigungen setzen sich nun zusammen aus:

- Soll-Beschleunigungsvektor, der die Fahrt beschreibt, und
- parasitäre Beschleunigungen auf Grund von
 - rotierenden Teilen (Motor, Unwucht der Räder),
 - Fahrbahnunebenheiten,
 - und aerodynamischen Eigenschaften des Fahrzeugs bei hohen Geschwindigkeiten.

Diese parasitären Krafteinwirkungen können nach Popp et al. (1993) wie folgt kategorisiert werden:

- periodisch, zum Beispiel Unwucht des Antriebs oder der Räder, Störkräfte aus dem Antrieb, modelliert als Fourierreihe

$$f(t) = \frac{a_0}{2} + \sum_{k=1}^{\infty} (a_k \cos k\omega t + b_k \sin k\omega t) \quad (6)$$

mit den Fourierkoeffizienten a_0, a_k und b_k , sowie der Kreisfrequenz ω . Für die Kreisfrequenz gilt $\omega = 2\pi / T_p$ wobei die Periodendauer mit T_p bezeichnet wird.

- impulsartig, zum Beispiel bei Überfahrt über ein Einzelhindernis

$$f(t) = s \delta(t - t_k) \quad (7)$$

mit der δ -Distribution zum Zeitpunkt t_k und s als Skalierungsfaktor der Anregung mit der Einheit Kraft · Zeit.

- regellos, zum Beispiel Störkräfte aus regellosen Fahrbahnunebenheiten, modelliert mit einer Verteilungsfunktion auf Basis von Mittelwert m_f und der Korrelationsfunktion $R_f(\tau)$, wobei τ die Korrelationszeit bezeichnet:

$$f(t) \sim (m_f, R_f(\tau)). \quad (8)$$

Durch die Einwirkung dieser störenden Kräfte auf das dämpfende System des Fahrzeugs werden erzwungene, gedämpfte Schwingungen unterschiedlicher Frequenz erzeugt. Sie liegen mit maßgeblichen Amplituden im Bereich von 0 bis 30 Hz [Harrison 2004, Braess et al. 2007, Schramm et al. 2010]. Diese Kräfte können nach Harrison (2004) unterteilt werden in

- primäre Fahrtstörungen (0 bis 6 Hz) von Fahrbahnunebenheiten

- sekundäre Fahrtstörung (6 bis 30 Hz) der Bewegung von Fahrzeugteilen (Rädern, Achsen, Antriebsstrang), dabei
 - Längsbeschleunigungsanteil (0 bis 15 Hz),
 - Querschleunigungsanteil (15 bis 20 Hz),
 - höhere Schwingungsmoden (30 bis 200 Hz) z. B. von Fahrzeugteilen.

Die Frequenzen der Soll-Beschleunigung liegen im Bereich der primären Fahrtstörung.

2.2.4 Der Mensch als Schwingungskoppler und Schwingungsquelle

Die Bewegung eines Sensors in einer ÖPV-Umgebung ist neben Fahrzeugschwingungen durch Schwingungen gekennzeichnet, die durch menschliche Bewegung entstehen und die durch den menschlichen Körper gedämpft oder verstärkt werden. Dieser Abschnitt befasst sich mit dem Menschen als Schwingungsquelle und -koppler.

Die im vorangegangenen Abschnitt vorgestellten Fahrzeugmodelle enthielten einfache Modelle für Personen im Fahrzeug. Wie Rützel (2007) diskutiert, gibt es neben diesem Modell, das auf der Arbeit von Coermann (1962) basiert, noch weitere phänomenologische Ganzkörpermodelle zur Modellierung von Schwingungen, die sich auf den gesamten menschlichen Körper beziehen (sog. Ganzkörperschwingungen).

In dieser Arbeit soll eine Person einen Sensor am Körper tragen oder in der Hand mit sich führen. Es ist somit ein kleinteiligeres Modell für eine detailliertere Betrachtung der vorhandenen Übertragungsfunktionen notwendig. Das in Abbildung 5 dargestellte Modell basiert auf der oft in der Literatur verwendeten Abbildung von Rasmussen (1982), anhand derer üblicherweise Resonanzfrequenzen menschlicher Körperteile diskutiert werden, siehe z. B. Pütz (2012) oder Malsch et al. (2007). Diese Resonanzfrequenzen liegen in dem Bereich der im Abschnitt 2.2.3 genannten primären und sekundären Fahrtstörungen und können sich negativ auf den Fahrtenkomfort auswirken [Pütz 2012].

Die in dieser Arbeit betrachtete Anwendung ist die Detektion von Anregungen des Fahrzeugs beispielsweise durch Überfahrt eines charakteristischen Bodenbelags oder die Durchfahrt einer Kurve. Der dazu verwendete Sensor kann von einer Person getragen werden. In diesem Fall ist die Auswirkung des menschlichen Feder-Dämpfer-System zu diskutieren und dessen Einfluss auf die Übertragung von Fahrzeugschwingungen auf den durch die Person getragenen Sensor zu beachten.

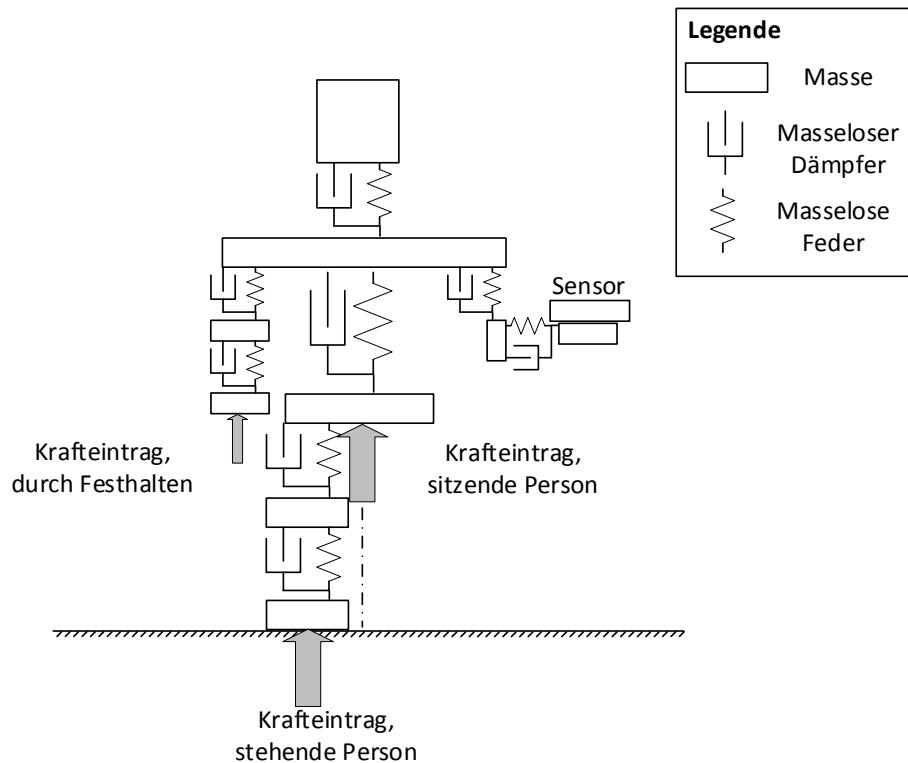


Abbildung 5: Mehrkörpermodell für eine Person, in Anlehnung an Rasmussen (1982) und von Gierke (1988)

Der Mensch ist Schwingungskoppler und durch seine Hüftbewegung während der Fortbewegung Schwingungserzeuger. Bei der menschlichen Fortbewegung auf zwei Beinen (die sog. Bipedie) existieren zwei wesentliche Grundformen: das langsame Gehen und das schnellere Laufen [Srinivasan et al. 2006]. Weitere Formen ergeben sich durch den Untergrund, beispielsweise beim Treppensteigen (gehend oder laufend) oder beim Berglauf in der schrägen Ebene.

Wesentliche Einflussfaktoren auf das durch die Bewegung der Person verursachte Schwingungssignal sind nach Weidmann (1993) und Bosina (2012):

- Physische Merkmale der Testperson (z. B. Gewicht, Schrittlänge),
- Lage/Montage des Geräts,
- Geschwindigkeit der Testperson,
- Steigung des zurückgelegten Weges,
- bei Treppen: Geometrie der Stufen.

Maßgebliche Frequenzen sind durch die Schrittfrequenz beeinflusst. Während die beim Gehen übliche Schrittfrequenz bei 1,6 bis 2,4 Hz liegt, können beim schnellen Laufen (Sprint) bis zu 5 Hz auftreten [Živanović et al. 2005, Cavagna et al. 1997]. Für das gehende Treppensteigen fand Bosina (2012) maßgebliche Schrittfrequenzen von 1,4 bis 1,6 Hz.

2.2.5 Erzeugung von Schwingungen im Labor

Die in den vorangegangenen Abschnitten beschriebenen Fahrzeug- und Personenschwingungen können nun zum einen in einer realen Verkehrssituation gemessen werden. Für systematische Tests von Anwendungen, die solche gemessenen Signale beispielsweise für Navigationsanwendungen verwenden, ist es wünschenswert, Fahrzeugschwingungen und personeninduzierte Schwingungen im Labor erzeugen zu können. Dazu sind Schwingtische (auch: Shaker, Rütteltische) hilfreich. Mechanismen zur Erzeugung von Schwingungen sind [Piersol et al. 2010, McConnell et al. 2008]:

- mechanisch (Direktantrieb oder Unwuchtanregung),
- elektrodynamisch (Magnetfeld- oder Induktionsanregung),
- hydraulisch.

Nach der Richtlinie zur Kalibrierung von Beschleunigungsmessgeräten nach dem Vergleichsverfahren der Deutschen Akkreditierungsstelle können zur Erzeugung der im Kontext dieser Arbeit auftretenden Sinus- oder Multisinusschwingungen elektrodynamische Schwingungserreger verwendet werden, die auf die Bewegung einer Spule im Magnetfeld beruhen. Der Schwingungserreger ist mit einem Masseblock fest zu verbinden, dessen Masse das 2000-fache der Masse des Schwingteils beträgt. Darüber hinaus sollte das System gegen Schwingungen aus der Umgebung isoliert werden. Dies erfolgt z.B. bei Aufstellung im Erd- oder Kellergeschoss mit einer Dämmschicht auf gewachsenem Boden. [DAkS 2010].

2.3 Beschleunigungsmessung

Zur Messung von Bewegungen kann die Aufzeichnung von Beschleunigungen dienen. Dieser Abschnitt fasst generelle Überlegungen zur Dimensionierung eines solchen Beschleunigungsmesssystems zusammen, das im Kapitel 3 für die in dieser Arbeit auftretende Messaufgabe übertragen und im Kapitel 4 angewendet wird. Dazu erfolgt die Diskussion der Messkette und möglicher Sensorprinzipien sowie zugehöriger Auswahlkriterien. Anschließend erfolgt eine Betrachtung zur Messunsicherheit dieses Messsystems.

2.3.1 Rechnergestütztes Messen

Zur Beschleunigungsmessung wird im Allgemeinen eine Messkette benötigt, die in Abbildung 6 dargestellt ist.




Abbildung 6: allgemeine Messkette (in Anlehnung an [León et al. 2012] und [Weichert 2010])

Beginn der Messkette ist das Messobjekt, dessen Eigenschaft über eine Messgröße von einem Aufnehmer gemessen werden kann und an dessen Ausgang ein Messsignal abgenommen werden kann. Dieses Messsignal wird mit Hilfe des Messumformers per Filterung für eine weitere Signalverarbeitung (zum Beispiel zur Signalklassifikation, wie im Unterkapitel 2.6 diskutiert) vorbereitet.

Eine solche Messkette ist immer störungsbehaftet. Relevante Einflüsse auf die Messunsicherheit werden im letzten Abschnitt dieses Unterkapitels diskutiert.

Dieser Messkette können nun die informationstechnische Begriffe Quelle, Senke, Signal und Information wie folgt zugeordnet werden [Hoffmann 1998]:

- Die Quelle ist das Messobjekt.
- Die Messgröße stellt die zu übertragenden Informationen dar.
- Die dargestellte Messkette, bestehend aus Aufnehmer, Messumformer, Signalverarbeitung und benötigter Verbindungen, bildet den Übertragungskanal.
- Der physikalische Träger (zum Beispiel Spannung), auf den die Information durch Modulation aufgeprägt wird, ist das Signal.
- Senke der Information ist eine Anwendung zur Analyse oder Nutzung der Information.
- Gleichzeitig ist die Information als Beseitigung von Ungewissheit [Bergmann et al. 2003] zu verstehen.

Betrachtet man nun den Informationsgehalt des an der Quelle anliegenden und des in der Senke anliegenden Signals, tritt durch die Informationsübertragung (z. B. Analog-Digital-Wandlung) Informationsverlust auf, der durch geeignete Verfahren zu minimieren ist (siehe Abschnitt 2.3.4). Die Redundanz eines Signals kann zur Sicherung gegen Informationsverlust verwendet werden, wenn die für die Anwendung wesentliche Information auf mehrere Arten im Signal verschlüsselt ist. Neben der Wahl eines günstigen Übertragungsmechanismus ab dem Sensor (siehe nächste Abschnitte 2.3.2 und 2.3.3) spielt die Datenverarbeitung samt geeigneter Merkmalsauswahl (siehe Unterkapitel 2.4 und 2.6) eine wesentliche Rolle im Prozess der Signalmessung und -klassifikation.

2.3.2 Kriterien zur Auswahl eines Beschleunigungsmessers

Zur Auswahl eines Beschleunigungssensors müssen nach Fraden (2010) diese Sensoreigenschaften betrachtet werden:

- *Hohe Sensitivität:* Diese Größe gibt das Verhältnis von Ausgangswert (analoger oder digitaler Datenwert eines elektrischen Messsignals) zu mechanischer Messgröße an und sollte genügend groß sein, d. h. eine kleine Änderung am Eingang bewirkt eine (genügend) große Änderung am Ausgang.
- *Hohe Auflösung:* Bei digitalen Signalen sollte die Quantisierung genügend fein erfolgen.
- *Lineare Übertragungsfunktion:* Diese kennzeichnet das Übertragungsverhalten des linearen, zeitinvarianten Systems im interessierenden Frequenzbereich. Ein solches System darf im Arbeitsbereich keine Verzerrungen im Frequenzbereich erzeugen.
- *Keine Resonanz im Messbereich:* Die Resonanzfrequenz, also diejenige entwurfsbedingte Frequenz, bei der eine deutlich stärkere Reaktion als bei benachbarten Frequenzen auftritt, sollte entfernt vom Messbereich liegen.
- *Keine Nullpunktfehler:* Verfahrensbedingt zeigen manche Sensortypen entlang der z -Achse die Erdbeschleunigung an, die zu berücksichtigen und gegebenenfalls zu eliminieren ist.
- *Geringer Linearitätsfehler:* Der Arbeitsbereich eines Sensors sollte derjenige sein, in dem das Messsignal linear von der Messgröße abhängt.

Zunächst ist zu klären, ob für einen gewünschten Arbeitsbereich, in dem Beschleunigungen aufgenommen werden sollen, ein geeigneter Sensor (siehe Abschnitt 2.3.3) existiert. Für diesen ist zu prüfen, ob die angegebenen Forderungen erfüllt sind. Weiterhin ist zu klären, wie die Messunsicherheit minimiert werden kann. Die Diskussion der Messunsicherheit ist Gegenstand des Unterkapitels 2.3.4.

2.3.3 Prinzipien der Beschleunigungsmessung

In dieser Arbeit werden, wie in Abschnitt 2.2.3 und 2.2.4 diskutiert, Frequenzen von 0 bis 30 Hz betrachtet. Für deren Messung wird im Normalfall die Messung der Auslenkung einer beschleunigten Masse verwendet [Fraden 2010]. Einen auf diesem Vorgehen beruhenden Sensor beschreibt Fraden (2010) als ein mit dem Freiheitsgrad 1 arbeitendes Gerät, das aus einer Masse, einem federartigen Haltesystem und einer Rahmenstruktur mit Dämpfungseigenschaften besteht.

Zur Beschleunigungsmessung kommen für den genannten Arbeitsbereich von 0 bis 30 Hz im Wesentlichen zwei Prinzipien in Frage [Piersol et al. 2010]:

- Kapazitives Messprinzip:

Das Beschleunigen der an einer Elektrode eines Plattenkondensators befestigten seismischen Masse bewirkt die Veränderung des Plattenabstandes, der über eine Messschaltung (z.B. „Wheatstonesche Messbrücke“ [Wheatstone 1843]) ausgewertet werden kann. Ein Sensor, der auf diesem Verfahren beruht, ist preiswert, einfach und bewährt, sowie für Detektion niedrigerer Frequenzen und von großen Auslenkungen (z.B. bei starken Stößen) geeignet. Sensoren dieser Bauart besitzen eine starke Temperaturabhängigkeit. Diese ist kompensierbar. [Fraden 2010]

- Piezoresistives Messprinzip:

Das Beschleunigen der seismischen Masse bewirkt durch Druck-/Zugkräfte eine elektrische Widerstandsänderung der Piezokristalle, die über eine Messschaltung (z.B. ebenfalls „Wheatstonesche Messbrücke“, [Weichert 2010]) erfasst werden kann. Dieses Verfahren kann über einen großen Frequenzbereich genutzt werden und nach diesem Prinzip arbeitende Sensoren besitzen eine gute Schockresistenz bis zu 10000g. [Fraden 2010]

Beide Verfahrensweisen benötigen zur Messung eine Hilfsenergiequelle. Solche Sensoren werden als aktive Sensoren bezeichnet.

Weitere Verfahren arbeiten nach Tränkler et al. (2014) u.a.

- magnetisch/induktiv,
- auf Basis des piezoelektrischen Effekts,
- basierend auf thermischen Effekten oder
- optisch.

Die genannten Verfahren sind prinzipiell mikroelektrisch-mikromechanisch (als engl. micro electrical micro mechanical system, kurz MEMS, „in MEMS-Technologie“) darstellbar. Zu beachten ist, dass die Miniaturisierung eine Verschlechterung der Sensitivität bedeutet [Gerlach et al. 2006].

In der auf einer Grafik von Colibris (2015) basierenden Abbildung 7 können das piezoresistive und das kapazitive Verfahren qualitativ verglichen werden.

Auf Grund der geringen Querempfindlichkeit zu Temperatur und Feuchtigkeit eignen sich kapazitive Sensoren besser für die in dieser Arbeit zu diskutierenden verkehrsbezogenen Anwendungen als das piezoresistive Verfahren [Colibris 2015].




Abbildung 7: Sensoreigenschaftenvergleich (in Anlehnung an [Colibris 2015])

Ein kapazitiver Sensor wird tendenziell gegenüber einem piezoresistiven Sensor eine verminderte Bandbreite, eine geringere maximale Beschleunigung, sowie die geringe Schockrobustheit besitzen. Diese Eigenschaften spielen jedoch für den Bereich der hier diskutierten Anwendungen keine Rolle.

In Smartphones sind häufig kapazitive Sensoren verbaut [Bosch 2014]. Gleichzeitig können diese Sensoren für Messplattformen genutzt werden [de 2016].

2.3.4 Betrachtungen zur Messunsicherheit

Das idealisierte Ziel einer Messung ist die wahrheitsgemäße Erfassung einer Messgröße. Es existiert in der Realität jedoch eine Messunsicherheit. Dieser Abschnitt diskutiert den Begriff der Messunsicherheit sowie Quellen von Messabweichungen.

2.3.4.1 Messabweichung

In Anlehnung an [DIN 1319-3] definiert Weichert et al. (2010) den Begriff „Messabweichung“ als die Differenz zwischen dem wahren Wert einer Größe und dem durch Messung bestimmten Wert.

Der wahren Wert ist in der Praxis nicht bestimmbar. Es ist somit das Ziel, das Vertrauensintervall, in dem der wahre Wert liegt (bezeichnet als Standard-Messunsicherheit), mit großer Genauigkeit zu schätzen [Weichert et al. 2010], z.B. auf Basis der statistischen Modellierung des Messprozesses [JCGM 2008].

2.3.4.2 Quellen von Messabweichungen

Neben den im Abschnitt 2.3.2 diskutierten Eigenschaften eines Sensors, die durch Alterung und Defekt veränderlich sind, sind äußere Störquellen klimatischer (Feuchtigkeit, Temperatur) oder elektrisch/elektromagnetischer (Felder) Natur wesentliche Quellen systematischer Messabweichungen. Je nach Anwendungsumgebung und Länge einer Messkampagne müssen solche Randbedingungen hinsichtlich ihres Einflusses auf die Messunsicherheit diskutiert werden.

Ein in jedem Fall zu betrachtender Entstehungsmechanismus für Messunsicherheit sind die Effekte bei der Analog-Digital-Umsetzung. Die Analog-Digital-Wandlung wird je nach Sensortyp sofort im Sensor oder an einer nachgeordneten Stelle in der Messkette durchgeführt, um die gesammelten Messwerten digital verarbeiten zu können.

Die wesentlichen Schritte der Analog-Digital-Umsetzung sind [Weichert et al. 2010]

- 1) Bandbegrenzung durch analogen Tiefpass-Filter unter Beachtung des Abtasttheorems,
- 2) Zeitliche Diskretisierung durch Abtast-/Halteglied,
- 3) Diskretisierung im Wertebereich durch Quantisierung.

In allen drei Schritten werden Messabweichungen und damit Informationsverluste auftreten, die durch die geeignete Dimensionierung der Schaltungen verringert werden können.

Bei der Quantisierung des Wertebereichs wird der Eingangswertebereich zwischen dem möglichen Minimum und dem möglichen Maximum in Stufen abgebildet. Je nach Verfahren können die Quantisierungsstufen von einheitlicher oder unterschiedlicher Größe sein. Wenn im Eingangswertebereich mehr Werte darstellbar sind als im digitalen Wertebereich – und somit ein digitaler Wert für verschiedene analoge Eingangswerte gilt – ist eine Umkehrung des Prozesses mit einer gewissen Unschärfe möglich. Die systematisch auftretende Abweichung kann als Quantisierungsrauschen modelliert werden. Die Größe der Abweichung hängt im starken Maß von der gewählten vertikalen Auflösung, also der Anzahl an Quantisierungsstufen und Wortbreite, ab. [Weichert et al. 2010]

Allerdings muss in der Praxis untersucht werden, ob dem zu digitalisierenden Signal vor der Quantisierung Rauschen hinzugefügt wurde (z. B. durch die Abtast-/Halte-Schaltung), sodass eine Verfeinerung der Quantisierung lediglich eine Verfeinerung der Darstellung des verrauschten Signals bewirken würde, jedoch keinen weiteren Genauigkeitsgewinn im Sinne der Repräsentation des Analogsignals. Die effektiv wirksame Auflösung eines Analog-Digital-Umsetzers, die in der Praxis unter der theoretisch möglichen liegt, wird mit der Kennzahl *ENOB* (engl. effective number of bits, Effektive Anzahl an bits) angegeben. [DIN EN 62008]

2.3.5 Entwurfsanforderungen an den Messaufbau

Beim Entwurf der für diese Arbeit benötigten Messsysteme müssen nach Weichert et al. (2010) folgende Forderungen beachtet werden, um dem Ziel einer getreuen Abbildung der Messgröße nahe zu kommen:

- Begrenzung der Fehlereinflüsse des Messumformers mittels geeigneter Sensorprinzipwahl,
- Vermeidung elektromagnetischer und elektrischer Störungen im Messaufbau durch geeignete Sensorplatzierung und ggf. Schirmung,
- Korrekte Wahl der Spannungsbereiche am Ein- und Ausgang mittels Aussteuerung des Sensors (Nutzung des Arbeitsbereiches ohne Übersteuerung) und des Schaltungsdesigns,
- Beachtung des Arbeitsbereiches hinsichtlich der zu erwartenden Frequenzen unter Beachtung von Abtastfrequenz und Anpassung der notwendigen Filter,
- Kontrolle reversibler Einflüsse auf das Messsignal, dass z. B. bei Hysterese der Arbeitsbereich immer auf gleiche Weise erreicht werden muss, sowie
- Kontrolle irreversibler Einflüsse auf das Messsignal, z.B. bei Alterung.

In Kapitel 4.1.2 werden die für diese Arbeit verwendeten Messsysteme beziehend auf die oben genannten Kriterien vorgestellt.

2.4 Zustandsmodelle menschlicher Bewegungsformen

Zur Systematisierung auftretender Bewegungszustände eignen sich Zustandsmodelle, die mehrere Zustände miteinander verknüpfen. In diesem Abschnitt werden stochastische Prozesse und Ketten als Zustandsmodelle eingeführt und auf die in dieser Arbeit betrachteten Bewegungszustände übertragen.

2.4.1 Stochastische Prozesse und Ketten

Die hier gewählte Darstellung von stochastischen Prozessen und Ketten basiert auf dem Kapitel „Wahrscheinlichkeitsrechnung“ von Bronstein et al. (2001).

Bei einem Zufallsversuch seien alle möglichen, einander ausschließenden Ausgänge als Elementarereignis bezeichnet. Diese Menge an Elementarereignissen lässt sich somit als Wertebereich einer Zufallsgröße X betrachten. Eine Menge von Zufallsgrößen wird dann als stochastischer Prozess bezeichnet, wenn diese Größen alle von ein und demselben Parameter, zum Beispiel der Zeit t , abhängen.

Sind bei einem stochastischen Prozess der Zustandsraum Z (die Menge der Werte der Zufallsgrößen) und der Parameterraum T (die Menge der Werte des Parameters, zum Beispiel der Zeitpunkte) diskret, nennt man diesen Prozess eine stochastische Kette.

In einer homogenen Markov-Kette n -ter Ordnung hängt ein zukünftiger Zustand von den n letzten Zuständen ab, nicht von weiter zurückliegenden Zuständen [Langrock et al. 1979]. Zugleich sind die Übergangswahrscheinlichkeiten zeitlich konstant. Abbildung 8 zeigt einen solchen Zustandsgraph für ein System mit zwei Zuständen sowie den zugehörigen Übergangswahrscheinlichkeiten A_{ij} .




Abbildung 8: Beispiel für eine Markov-Kette mit zwei Zuständen und zugehörigen Übergangswahrscheinlichkeiten

2.4.2 Anwendung auf Bewegungszustände

Die menschliche Bewegung kann als ein Zufallsprozess aufgefasst werden, der mit einer solchen Markov-Kette dargestellt werden kann. Beispiele finden sich bei Widhalm et al. (2012), Parlak et al. (2011), Lester et al. (2005, 2006) und Reddy et al. (2010). Auch in der Verkehrswissenschaft definierte Reiseketten können als Zustandsmodelle interpretiert werden.

Multimodale ÖPV-Reiseketten, das heißt Reiseketten, bei denen mehr als eine ÖPV-Fahrzeugart genutzt wird, bestehen im Allgemeinen aus diesen Komponenten [Krygsmann et al. 2004]:

- Zugang: Bipedie (i.A. Gehen), Radfahren, oder motorisiert (PKW, Taxi)
- Warten
- Nutzung eines ÖPV-Fahrzeugs (Bus, Straßenbahn, Zug, U-Bahn, spezielle Typen (z. B. Fähre, Bergbahnen))
- Gegebenenfalls Transfer und weitere Fahrzeugnutzung
- Abgang: Bipedie (i.A. Gehen), Radfahren, oder motorisiert (PKW, Taxi)

Zur Ermittlung von Übergangswahrscheinlichkeiten können die unter anderem von Dandy et al. (1984) fallspezifisch untersuchten Dauern von Reisezeitkomponenten sowie die von Ahrens et al. (2009) für verschiedene Städte Deutschlands bestimmten Mobilitätskennzahlen für den Untersuchungszeitraum 2008 herangezogen werden.

Aufbauend auf den Ausführungen zur allgemeinen multimodalen Reisekette und den Kennzahlen von Ahrens et al. (2009) und Dandy et al. (1984) für ein Oberzentrum wie die Region Dresden mit mehr als 500 000 Einwohnern wird für Analysen dieser Arbeit (z.B. bei der Erzeugung von Testsignalen) eine Reisekette als typisch angenommen, wie sie in Tabelle 1 zusammengefasst ist.

Tabelle 1: Reisezeitkomponenten einer typischen Reisekette nach Ahrens et al. (2009) und Dandy et al. (1984)

Komponente	Modus	Mittlere Dauer in Minuten
Zugang: Fußweg vom Start zur Haltestelle	Bipedie	4
Wartezeit an der Haltestelle	Ruhe	2
ÖV-Nutzung: Fahrzeit mit Bus	Bus	8
Transfer zwischen Haltestellen oder -steigen	Fuß	2
ÖV-Nutzung: Fahrzeit mit Straßenbahn	Straßenbahn	10
Abgang: Fußweg von der Haltestelle zum Ziel	Bipedie	5

Diese angenommenen Zustandsmodelle können geschichtet formuliert sein. Zum Beispiel formulieren Parlak et al. (2012) ein hierarchisches Zustandsmodell, in dem für das Laufen, das Fahrradfahren und die motorisierte Fortbewegung jeweils eigene Zustandsmodelle existieren.

Lee et al. (2011) unterscheiden zwei globale Bewegungsmodi („statisch“ und „dynamisch“) und unterteilen diese Modi in detaillierte Bewegungszustände. Ähnlich verfahren Mathie et al. (2004) mit einer Unterscheidung in Aktivitätslevel („Aktivität“ und „Ruhe“), sowie Bewegung und Unterbewegungen für die Aktivitäten.

2.5 Signalanalyse

Zur Bestimmung von Bewegungszuständen ist es notwendig, die gemessenen Beschleunigungssignale zu analysieren. Die Methode der Signalanalyse stellt dazu verschiedene Betrachtungsweisen – sogenannte Analysedomänen – zur Verfügung. Die Signalanalyse ist die Voraussetzung für die in Abschnitt 2.6 vorgestellte Signalklassifikation.

2.5.1 Überblick zu Analysedomänen

Zwecks Auswahl eines Signalanalysewerkzeugs ist vorher zu klären, welche Signalart vorliegt und in welchem Zustandsbereich die Analyse stattfinden soll.

Signale können in verschiedene Kategorien eingeteilt werden [Hoffmann 1998], z. B. nach

- Definitions- und Wertebereich in Analog-, Treppen-, Abtast- oder Digitalsignal.
- dem zu Grunde liegendem mathematischen Modell in deterministisches oder stochastisches Signal.
- Veränderlichkeit der Parameter des mathematischen Modells über der Zeit in stationäres (konstante Verteilungsparameter), quasistationäres (abschnittsweise konstante Verteilungsparameter) oder instationäres Signal (zeitlich variable Verteilungsparameter). Aus instationären Signalen können durch (bezogen auf die Änderung der Verteilungsparameter) kurze Betrachtungsintervalle quasistationäre Signale erzeugt werden.

Im Rahmen dieser Arbeit werden digitale, instationäre Sensorsignale im Zeit- und Frequenzbereich betrachtet.

2.5.2 Signalanalyse im Zeitbereich

Nach Figo et al. (2010) sind wesentliche Analysewerkzeuge für Beschleunigungssignale im Zeitbereich deskriptive statistische Kenngrößen, siehe [Zöfel 2003, Bronstein et al. 2001, Hochstädter 1991], mit:

- Häufigkeitstabellen (z. B. beobachtet, prozentual, kumuliert)
- Lageparameter der Messwerteverteilung, wie arithmetischer, geometrischer und harmonischer Mittelwert, Median, Modalwert,
- Streuungsparameter der Messwerteverteilung, wie
 - Spannweite
 - Durchschnittliche absolute Abweichung,
 - Standardabweichung, Variationskoeffizient, Varianz, Standardfehler, Mittlerer quadratischer Fehler,
 - Perzentile inkl. 0-Perzentil (Minimum) und 100-Perzentil (Maximum),
- Schiefe der Messwerteverteilung

Eine gängige Darstellungsform der explorativen Signalanalyse ist der Boxplot, der die Verteilung einer Stichprobe mit Median, Quartil-Grenzen, Minimum und Maximum sowie gegebenenfalls Ausreißern zusammenfasst.

Weiterhin kommen diese Maße in Betracht:

- Korrelationsmaße zwischen aktuell gemessenem Signalabschnitt und einem früheren gemessenen Signalabschnitt, wie Signalkorrelation oder Kovarianz,
- informationstheoretische Maße, wie die Entropie,
- Distanz-/Ähnlichkeitsmaße zwischen aktuell gemessenem Signalabschnitt und einem früheren gemessenen Signalabschnitt,
- Signalenergie (Summe der Betragsquadrate, gemittelt über Signallänge)
- weitere Signalcharakteristika, wie
 - Stichprobendifferenzen,
 - Anzahl der Nulldurchgänge,
 - numerisches Integral,
 - Signalzusammenfassungen, wie sie für dreidimensionale Beschleunigungsmessungen durchführbar sind, zum Beispiel als vektorielle Winkel und Winkelgeschwindigkeiten, sowie der Betrag des Signalgesamtvektors,
 - Prominenz von lokalen Maxima (Abstand in y -Richtung zwischen letztem lokalen Minimum und betrachtetem lokalen Maximum, siehe [Kohla 2013])

Diese Kenngrößen können für gezielt gefilterte Signalanteile berechnet werden.

2.5.3 Signalanalyse im Frequenzbereich: Fourier- und Wavelet-Analyse

Eine weitere signalanalytische Möglichkeit liegt in der Betrachtung des Signals im Frequenzbereich, wie z. B. von Hoffmann (1998) dargestellt. Diese ist für die Analyse von auf Schwingungen beruhenden Bewegungen geeignet (Abschnitt 2.2.2).

Die grundsätzliche Idee der Wavelet-Analyse besteht in der Berechnung einer Korrelation zwischen dem zu betrachtenden Signal und zeitlich verschobenen und gestauchten Schwingungsprototypen, sogenannten Kernen. Im Fall der klassischen Fourier-Analyse als Spezialfall der Wavelet-Analyse sind dies Sinus- und Kosinusschwingungen. Die Transformationsvorschrift für ein Signal $x(t)$ lautet auf Basis der komplexen Euler-Funktion $e^{-j\omega t}$, die Sinus- und Kosinusschwingungen vereinigt,

$$X(\omega) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j\omega t} dt. \quad (9)$$

Für digitale und gefensterte Signale wird die Fourieranalyse als FFT effizient rechentechnisch umgesetzt.

Diese Theorie kann mit Hilfe der Wavelet-Analyse auf diejenigen Kerne erweitert werden, bei denen die Schwingung am zeitlichen Anfang und Ende des Kerns ein- bzw. ausgeblendet werden. Solche Kerne heißen „wavelets“ (von frz. ondelette, dt. Wellchen) [Sauer 2012].

Die allgemeine Transformationsvorschrift für ein Signal $x(t)$ mit Hilfe einer Wavelet-Funktion Ψ , die mit dem Stauchungsparameter a und dem Verschiebungsparameter b arbeitet, lautet [Sauer 2012]:

$$T(a,b) = \int_{-\infty}^{\infty} x(t) \cdot \Psi_{a,b}(t) dt. \quad (10)$$

Die entstehenden Spektren können mittels dieser Kenngrößen charakterisiert werden [Figo et al. 2010], [Preece et al. 2009], [Theodoridis et al. 2009], z. B.:

- Dominante Frequenz (Frequenz mit größter Amplitude),
- Koeffizientensummen über die ersten n Frequenzen,
- Spektrale Energiedichte (Summe der quadrierten Koeffizienten),
- Spektrale Entropie,
- Spektraler Roll-off (Frequenzwert bis zu dem bei Aufsummierung der quadrierten Koeffizienten $x\%$ der Gesamtsignalenergie erreicht wird).

2.5.4 Signalkorrelation

Zum Bewerten der Ähnlichkeit von Signalen wird, wie in [Seydel 2008] dargestellt, üblicherweise für metrisch skalierte Daten der Korrelationskoeffizient mit der Gleichung

$$r_{a,b} = \frac{\sum_{j=1}^n (x_{ja} - \bar{x}_a) \cdot (x_{jb} - \bar{x}_b)}{\sqrt{\sum_{j=1}^n (x_{ja} - \bar{x}_a)^2 \cdot \sum_{j=1}^n (x_{jb} - \bar{x}_b)^2}} \quad (11)$$

herangezogen. Für die Betrachtung der Korrelation zwischen zwei Messreihen ist \bar{x}_a der Durchschnittswert über alle Messwerte einer Messreihe a und x_{ja} der Messwert j der Messreihe a . Analog erfolgt die Bezeichnung für Messreihe b . Ähnlichere Messwertverläufe werden mit höherer Ähnlichkeit bewertet, wobei die Niveauhöhe der Messwertverläufe unbetrachtet bleibt. Die größte Ähnlichkeit besitzen Objekte mit dem Wert 1.

Zur Interpretation von Korrelationskoeffizienten werden üblicherweise diese betragsmäßigen Schranken angesetzt [Zöfel 2003]:

- $|r|$ 0 bis 0,2 sehr geringe Korrelation,
- $|r|$ 0,2 bis 0,5 geringe Korrelation,
- $|r|$ 0,5 bis 0,7 mittlere Korrelation,
- $|r|$ 0,7 bis 0,9 hohe Korrelation,
- $|r| > 0,9$ sehr hohe Korrelation.

Zu beachten ist, dass durch diese Kennzahl die Stärke eines linearen Zusammenhangs analysiert werden kann. Andere nichtlineare Zusammenhänge können nicht bewertet werden.

2.6 Signalklassifikation zur Zustandserkennung

Für die Identifikation von Bewegungszuständen wird das Werkzeug der Signalklassifikation zur Zuordnung von Bewegungssignalen zu Bewegungszuständen verwendet. Es wird zunächst die prinzipielle Herangehensweise der Signalklassifikation beschrieben. Es folgt eine Übersicht zu Klassifikatoren und eine Einführung zu dem in dieser Arbeit verwendeten Hidden Markov Model-Klassifikator. Den Abschluss bildet die Diskussion von Bewertungsmöglichkeiten der Klassifikationsleistung. Dieser theoretische Überblick bildet die Grundlage für den in Kapitel 3.4 entworfenen Klassifikator.

2.6.1 Generelle Herangehensweise

Für die Arbeit mit Klassifikatoren werden grundsätzlich zwei Phasen benötigt [Jain et al. 2000]: die Trainings- oder Lernphase (in Abbildung 9 unterer Teil) und die Klassifikationsphase (in Abbildung 9 oberer Teil).

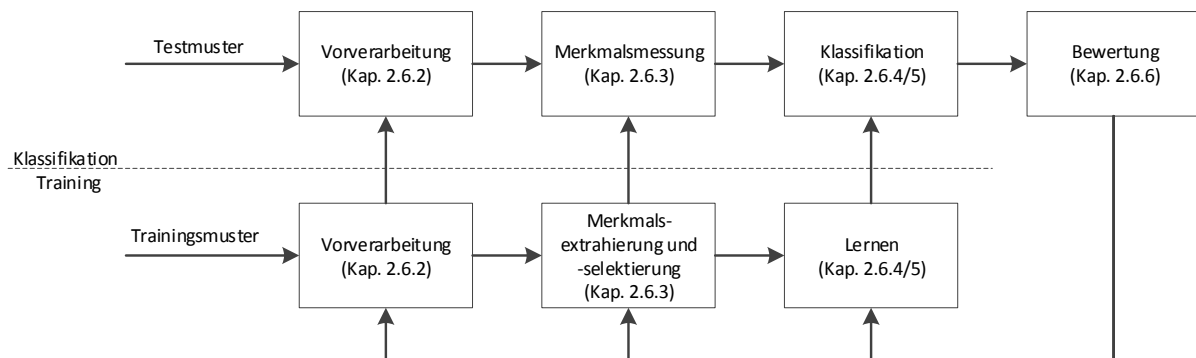


Abbildung 9: Der Klassifikationsprozess (nach Jain et al. (2000))

2.6.1.1 Trainingsphase

Wesentliche Arbeitsschritte in der Trainingsphase sind Vorverarbeitung, Merkmalsextraktion und Merkmalsselektion sowie die Festlegung und das Anlernen der Klassifikatorstruktur.

Nach Jain et al. (2000) ist die wesentliche Rolle der Vorverarbeitung das Herausheben der Signalinformation über einen Zustand vom Hintergrund. Diese Information kann als Muster interpretiert

werden. Man spricht daher von Mustererkennung. Weiterhin wird das Rauschen gefiltert, gegebenenfalls Normierungsverfahren angewandt sowie anderen Operationen durchgeführt, die zu einer kompakten Repräsentation der in dem Signalabschnitt enthaltenen Information beitragen. Dieser Schritt wird im Abschnitt 2.6.2 beschrieben. Aufbauend auf diesen Schritt sind die Merkmalsextraktion und -verdichtung dafür zuständig, die passenden Merkmale zu finden, die die zu identifizierenden Zustände beschreiben (siehe Abschnitt 2.6.3). Im Lernschritt lernt nun der Klassifikator, den Merkmalsraum aufzuteilen. Je nach Art des Systems wird die Trainingsphase beim Entwurf (fest parametrisiertes System), oder mehrfach im Betrieb (adaptives System) durchlaufen. In adaptiven Systemen ermöglicht die Rückkopplungsschleife die Optimierung der Vorverarbeitung sowie die Merkmalsextraktion und -selektion.

2.6.1.2 Klassifikationsphase

In der Klassifikationsphase wird der angelernte Klassifikator für unbekannte Testsignale verwendet. Dazu müssen diese Daten ebenfalls vorverarbeitet und die in der Lernphase als relevant bewerteten Merkmale gemessen werden. Anschließend sollte die Bewertung des Klassifikationsergebnisses erfolgen (Abschnitt 2.6.6) und gegebenenfalls die Anpassung der gesamten Klassifikator-kette angestoßen werden (Initialisierung der Rückkopplungsschleife in adaptiven Systemen).

2.6.2 Vorverarbeitung

Unverarbeitete Messdaten sind verrauscht, lückenbehaftet und inkonsistent [Han et al. 2006]. Die Vorverarbeitung ist ein wesentlicher Schritt, um zu einer kompakten Musterrepräsentation und damit zu einem effektiven Lernverfahren zu gelangen.

Wesentliche Methoden der Vorverarbeitung sind [Han et al. 2006]

- Deskriptive Statistik: Ermittlung von typischen statistischen Parametern
- Datenbereinigung
 - Datenlücken beheben
 - Datenglättung (Filterung)
 - Ausreißeridentifikation und -eliminierung
 - Inkonsistenzen beseitigen
- Datenintegration: Vereinigung von Daten aus verschiedenen Datenquellen durch Resampling
- Datentransformation: Standardisieren
- Datenreduktion

- Datenaggregation im Sinne einer Merkmalsextraktion
- Merkmalsreduktion

2.6.3 Merkmalsextraktion und -verdichtung

Merkmale dienen der kompakten Repräsentation von Datenmengen, die prinzipiell wie folgt gewonnen werden können [Niemann 2003]:

- nach der heuristischen Methode, bei der man versucht, Merkmale aufgrund von Intuition, Phantasie und Erfahrung zu finden.
- nach der analytischen Methode, bei der man versucht, optimale Merkmale systematisch abzuleiten.
- in einer kombinierten Methode.

Zur Erzeugung stehen die Methoden der Signalanalyse aus Abschnitt 2.5 zur Verfügung.

Je nach Anwendungsfall sind unterschiedliche Merkmale zielführend [Theodoridis et al. 2009, Duda et al. 2001]. Niemann (2003) stellt dazu eine breitgefaste Übersicht zur Verfügung.

In dieser Arbeit sollen Beschleunigungssignale klassifiziert werden. Es handelt sich um die Beobachtung eines nichtstationären Prozesses, der durch die Überlagerung von unterschiedlichen Schwingungsvorgängen gekennzeichnet ist [Piersol et al. 2010]. Für diese Aufgabe haben unter anderem Preece et al. (2009), Figo et al. (2010) und Mannini et al. (2010) Übersichten zu möglichen Merkmalen erarbeitet. Preece et al. (2009) und Figo et al. (2010) kamen in ihren Arbeiten unabhängig voneinander zu dem Schluss, dass einfache Merkmale in der Zeitdomäne für diese Anwendungen zu guten Klassifikationsergebnissen kommen, und das bei niedrigem Rechenaufwand. Es bleibt zu diskutieren, ob eine höhere Informationsausbeute eines aufwändig zu berechnenden Merkmals den Rechenaufwand – je nach Anwendung – aufwiegt. [Partzsch 2012] Ein mögliches Kriterium ist, ob zwei Zustände auf Basis der gewählten Merkmale eindeutig trennbar sind [Theodoridis et al. 2009].

Anschließend kann eine Bewertung und Auswahl der Merkmale mit höchstem Informationsgehalt mittels Korrelations- oder Hauptkomponentenanalyse hilfreich sein [Hall 1999].

Eine unterschiedliche Wichtung der Merkmale ist möglich.

2.6.4 Klassifikation

Ziel der Klassifikation ist es, auf Basis von gut separierenden, ggf. verdichteten Merkmalen Entscheidungen über die Zugehörigkeit eines Objekts zu Gruppen zu treffen.

2.6.4.1 Übersicht

Es gibt eine Vielzahl an Klassifikatoren. Sie werden oft unterteilt in [Jain et al. 2000], [Mannini et al. 2010]:

- Template Matching: hier wird mittels Ähnlichkeit zu einer Referenz klassifiziert,
- stochastische Klassifikation: die Klassifikation erfolgt wahrscheinlichkeitsbasiert,
- strukturelle Klassifikation: die Klassifikation erfolgt durch Zerlegen in einzelne Primitive,
- geometrische Verfahren: Im Merkmalsraum werden lineare oder nichtlineare Grenzflächen festgelegt, die über die Zugehörigkeit zu einer Klasse entscheiden.

Weitere Unterscheidungsmerkmale sind unter anderem:

- Adaptivität: lernend oder fest dimensioniert [Jain et al. 2000],
- Überwachung des Klassifikatorergebnisses: Verwendung vorgegebener Klassen oder datengetriebener Aufbau der Klassifikatorstruktur [Mannini et al. 2010],
- Dimensionalität der Eingangsdaten: Anzahl der Merkmale und zeitliche Ausdehnung des zu klassifizierenden Objektes [Hoffmann 1998].

Die in dieser Arbeit gegenständliche Aufgabe der Klassifikation von Beschleunigungsdaten mit dem Ziel einer Bewegungsklassifikation kann mit einem Klassifikator gelöst werden, der diese Eigenschaften besitzt:

- er arbeitet numerisch, weil die zu klassifizierenden Objekte Zahlen sind,
- er muss Zeitreihen klassifizieren können, weil die Objekte Zeitreihen sind,
- er arbeitet überwacht, weil die Zugehörigkeit der Objekte für den Trainingsdatensatz bekannt ist, und
- er kann statistisch arbeiten, weil eine Menge an Objekten vorhanden ist, die das Berechnen von Merkmalsverteilungen ermöglicht.

Dazu kommen verschiedene der oben angesprochenen Verfahrensklassen in Frage. Es werden nun exemplarisch Entscheidungsbäume sowie die Klassifikation auf Basis der Diskriminanzanalyse vorgestellt und für die spätere Analyse der Bewegungsdaten verwendet. Die Entscheidung für diese beiden Klassifikatortypen ist willkürlich. Während die Diskriminanzanalyse ein statistisch fundiertes Werkzeug ist, können Entscheidungsbäume, wie sie nachfolgend verwendet werden auf Basis einer empirischen Datenanalyse mit Hilfe von Expertenwissen erstellt werden. Letztere zeichnen sich mit einer hohen Robustheit bei kleineren Datenmengen aus. [Fink 2003]

2.6.4.2 Entscheidungsbäume

Ein Entscheidungsbaum ist ein mehrstufiges Entscheidungssystem, bei dem Klassen stufenweise abgelehnt werden, bis eine Klasse verbleibt, die akzeptiert wird [Theodoridis et al. 2009]. Das Verfahren kann mittels eines Graphen aus Knoten und Kanten, wie in Abbildung 10 gezeigt, dargestellt werden. Dieser beginnt bei der Baumwurzel und in jedem Knoten wird ein Entscheidungskriterium getestet, bis ein finaler Knoten (Blatt) eines Zweigs erreicht ist.

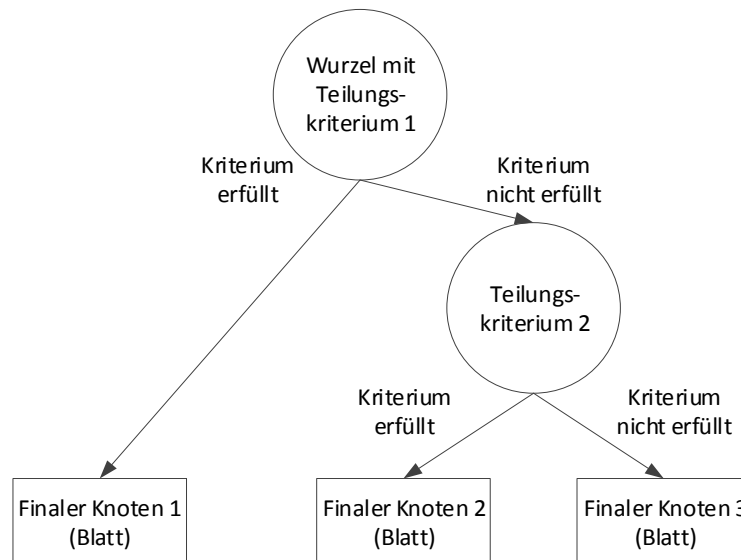


Abbildung 10: Beispiel für einen Entscheidungsbaum

Solche Bäume können auf Basis von empirischem Expertenwissen erstellt werden, wie z. B. von Mathie et al. (2004) diskutiert. Es gibt Algorithmen zur automatischen Erstellung eines Entscheidungsbaumes, wie zum Beispiel den CART-Algorithmus von Breiman et al. (1984).

2.6.4.3 Statistische Klassifikation mittels Diskriminanz-Analyse-Klassifikatoren

Statistische Klassifikatoren modellieren das zur Verfügung stehende Hintergrundwissen über die Verteilung der Merkmale im Merkmalsraum mittels Wahrscheinlichkeitsverteilungen. Über diese Verteilungen einer Lernstichprobe kann dann a posteriori eine wahrscheinlichkeitsbasierte Aussage über die Klassenzugehörigkeit für die Merkmale eines Testfalls getroffen werden. Bei n Merkmalen ist eine Beschreibungsmöglichkeit eine n -dimensionale Normalverteilung. Für jedes Merkmal existiert eine mit dem Mittelwert μ und der Streuung σ verteilte Normalverteilung [Fisz 1958] und deren Dichtefunktion $p(x)$:

$$x \sim \mathcal{N}(\mu, \sigma^2) \text{ mit } p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}. \quad (12)$$

Diese Modellierungsweise der Merkmale verwendet einfache, unimodalen Verteilungsfunktionen.

Für komplexere Sachverhalte empfiehlt sich die Modellierung mittels Gausscher Mischverteilungsmodelle. Eine allgemeine Dichtefunktion $p(x)$ kann als eine Linearkombination aus unendlich vielen einzelnen Normalverteilungen aufgefasst werden [Yakovitz 1970]:

$$p(x) = \sum_{i=1}^{\infty} c_i \mathcal{N}(x | \mu_i, \mathbf{K}_i) \text{ mit den Wichtungsfaktoren } c_i, \sum_{i=1}^{\infty} c_i = 1 \quad (13)$$

Anstelle der einzelnen Streuungen treten dann Kovarianzmatrizen \mathbf{K}_i . So kann für jedes Merkmal eine Mischverteilung aufgestellt werden, um der Verteilungsform besser gerecht zu werden.

Insgesamt besteht für diesen Ansatz das grundlegende Problem, dass die Trainingsdaten die Realität gut abbilden müssen, da die Gefahr der Überanpassung besteht [Fink 2003].

Im Fall der Diskriminanzanalyse wird nun diejenige Trennfunktion gesucht, bei der das Verhältnis zwischen Klassenabständen und Standardabweichungen innerhalb der Klassen maximiert wird [Fisher 1936].

Es kann gezeigt werden, dass diese Trennfunktion quadratische Terme besitzen kann [Hoffmann 1998]. Es gibt zwei Arten der Diskriminanzanalyse:

- die auf Fisher (1936) zurückgehende lineare Diskriminanzanalyse: hier verwendet das Modell für jede Klasse die gleiche Kovarianzmatrix, lediglich die Klassenmittelwerte sind variabel.
- die quadratische Diskriminanzanalyse: hier variieren für jede Klasse die Mittelwerte und die Kovarianzmatrizen.

Die Entscheidung über eine Klassenzugehörigkeit erfolgt bei einer Diskriminanzanalyse-basierten Klassifikator nach dem Wahrscheinlichkeitskonzept [Eckey et al. 2002].

Hierbei wird für einen bekannten Merkmalsvektor \mathbf{x} diejenige Klasse k aus K gewählt, für die die bedingte Wahrscheinlichkeit $P(k | \mathbf{x})$ maximal ist. Diese Entscheidung kann von den Kosten für eine Fehlentscheidung abhängig gemacht werden und führt dann zu einer Minimierungsaufgabe des Kostenrisikos [Hoffmann 1998].

2.6.5 Hidden Markov Model-Filterung

Nach der Klassifikation (siehe Abbildung 12) kann die Folgenstruktur des beobachteten Prozesses einbezogen werden. Ein geeigneter Ansatz ist die Modellierung des Prozesses mittels Hidden Markov Models (HMM) [Hoffmann 1998]. Dies ist ein Spezialfall des Bayesschen Netzes, für das Jung-hans (2009) Anwendungen im Verkehrsbereich aufgezeigt hat.

Das HMM ist ein stochastisches Modell, mit dem die Zustände eines Systems durch eine Markov-Kette modelliert werden (siehe Abschnitt 2.4.1). Bei dem HMM-Ansatz wird im Unterschied zur klassischen Markov-Kette davon ausgegangen, dass diese Zustände nicht beobachtbar (verborgen, engl. hidden) sind. Es kann anhand von Ausgabesymbolen, sogenannten Emissionen, auf die inneren Zustände geschlossen werden, die je nach Zustand mit gewissen Wahrscheinlichkeiten auftreten [Fink 2003], wie in Abbildung 11 dargestellt.

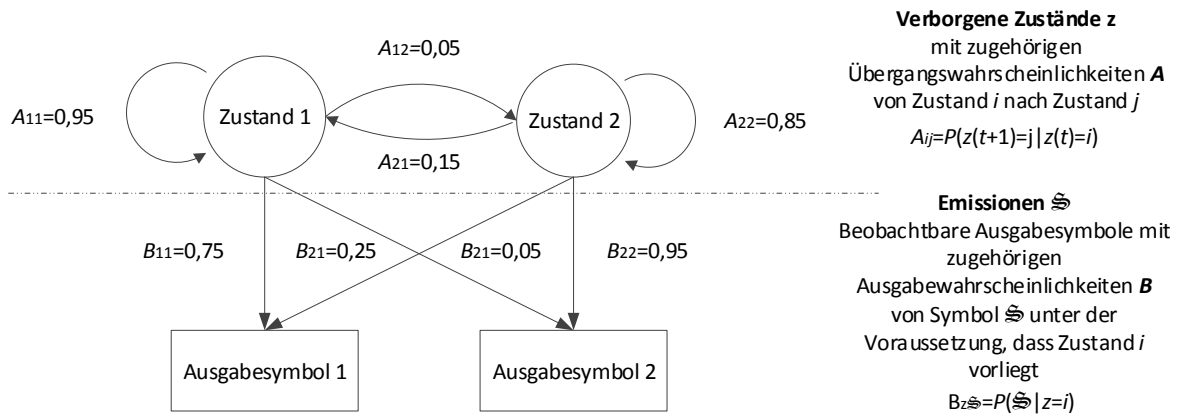


Abbildung 11: Beispiel für ein HMM mit zwei Zuständen und zwei Ausgabesymbolen

Dieser Ansatz lässt sich zur Klassifikation verwenden, in dem man das Modell als Repräsentation von Musterklassen betrachtet, wie Fink (2003) gezeigt hat: Werden für ein Signal Merkmale wie im Abschnitt 2.6.1 generiert, entspricht das den Emissionen auf deren Basis die innere Zustandsfolge, das heißt die zugehörige Klasse, bestimmt werden kann. Ein solches Vorgehen benötigt bei erhöhter Klassenanzahl eine große Menge an Daten. Bei zu kleinen Trainingsdatensätzen besteht die Gefahr der Überanpassung [Ghahramani 2001]. Zur Vermeidung des letztgenannten Problems können Modelluntereinheiten gebildet werden. Dazu eignen sich Entscheidungsbäume [Fink 2003], die als grundlegender Klassifikationsansatz im Abschnitt 2.6.4 erläutert wurden.

Im Kontext der Bewegungserkennung nutzen Reddy et al. (2012) Kombinationen von Entscheidungsbäumen und HMM. Parlak et al. (2012) nutzen die Erweiterung auf Basis von Random Forests. Beiden Ansätzen ist gemein, dass die Klassifikation mittels Entscheidungsbäumen durchgeführt und das HMM zur Glättung des Klassifikationsergebnisses verwendet wird.

2.6.6 Test und Bewertung von Klassifikatoren

Die Bewertung eines Klassifikators erfolgt in der Regel auf Basis von Testdaten, die nicht gleichzeitig Lerndaten waren. Bei kleineren verfügbaren Datensätzen ist der Ansatz der Kreuzvalidierung möglich, bei der Untermengen des Gesamtdatensatzes zum Lernen verwendet werden [Bishop 2006].

Ausgangspunkt für die Bewertung von Klassifikatoren ist die Verwechslungsmatrix \mathbf{V} , die nach Hoffmann (1998) in einer allgemeinen Form einschließlich Zurückweisungen mit den Elementen $v(e,k)$ wie folgt dargestellt werden kann, wenn e der Zähler für die K Klassifikatorentscheidungsklassen und k der Zähler für die tatsächlich vorliegende Klasse angeben:

$$\mathbf{V} = \begin{pmatrix} v(0,1) & v(0,2) & \cdots & v(0,K) \\ v(1,1) & v(1,2) & \cdots & v(1,K) \\ \vdots & \vdots & & \vdots \\ v(e,1) & v(e,2) & \cdots & v(e,K) \end{pmatrix}. \quad (14)$$

Eine solche Darstellung lässt Rückweisungen ($e=0$) zu, mit denen unsichere Entscheidungen vermieden werden können und so die Anzahl der Fehlentscheidungen minimiert wird. Auf der Hauptdiagonalen des unteren Teils der Matrix ($e=1, \dots, K$) befinden sich die Häufigkeiten der korrekt getroffenen Entscheidungen (nachfolgend als Korrektheit bezeichnet), während außerhalb der Hauptdiagonalen die Verwechslungen zu finden sind.

Für den Zweiklassenfall können aus der Verwechslungsmatrix eine Vielzahl weiterer Bewertungsgrößen wie die Richtig-Positiv-Rate (auch: Sensitivität, Trefferquote) und die Falsch-Positiv-Rate (auch: Fehlalarm) direkt abgelesen werden [Witten et al. 2011], [Theodoridis et al. 2009], [Berthold et al. 2003].

Die Fehler können als Trainingsfehler (Fehler auf Grundlage der Lernbasis) oder Generalisierungsfehler (Fehler auf Grundlage der von der Lernbasis verschiedenen Testbasis) bezeichnet werden.

2.7 Beitrag der vorliegenden Arbeit

Wie im Abschnitt 2.1 erläutert, wurde festgestellt, dass der Schwerpunkt der wissenschaftlichen Arbeit bisher auf der automatisierten Klassifizierung von Bewegungsdaten mobiler Endgeräte (Smartphones, medizinische Sensorik) lag.

Über diesen Stand der Technik und Wissenschaft hinausgehend wird in dieser Arbeit die vergleichende Analyse von Bewegungsdaten aus Fahrzeugen und von mobilen Sensorplattformen vorgestellt. Damit wird ein Beitrag zum Verständnis von Bewegungsdaten unterschiedlicher Herkunft geschaffen. Die geschlossene Darstellung ab der Signalentstehung bis zur Signalanalyse und -klassifikation für wesentliche im Öffentlichen Personenverkehr vorkommende Zustände und damit mögliche Signalquellen steht im Vordergrund. Zudem wird in dieser Arbeit die labortechnische Generierung der Schwingungen diskutiert.

Es werden somit diese, in den bei der Literaturrecherche betrachteten Veröffentlichungen noch nicht beantworteten Fragestellungen, adressiert:

1. *Welche Nutz- und Störsignalquellen sind in einer ÖPV-Umgebung bei der Erfassung von Bewegungszuständen auf Basis von Beschleunigungssignalen, die mittels mobiler Endgeräte erfasst werden, relevant?*
Abschnitt 3.2, sowie die Abschnitte zur Messtechnik und Signalanalyse in den jeweiligen Unterkapiteln des Kapitels 4 sind der Beantwortung dieser Frage gewidmet.
2. *Welche Bewegungszustände können über die Entscheidung für ein Verkehrsmittel (nachfolgend: Bewegungsmodus) hinaus in einer ÖPV-Umgebung erfasst werden?*
Die Antwort auf diese Frage ist Kern der Abschnitte 3.3 und 3.4, sowie des Kapitels 4.
3. *Wie können Beschleunigungssignale für reproduzierbare Anwendungstests in einer Laborumgebung wiedergegeben werden?*
Diese Frage wird im Kapitel 5 beantwortet.
4. *Bei welchen Anwendungsfällen können Bewegungsklassifikatoren im ÖPV-Kontext eingesetzt werden?*
Diese Frage wird im Kapitel 6 beantwortet.

Abbildung 12 zeigt die für diese Arbeit gewählte Vorgehensweise. Zunächst werden die Bewegungssignale aufgenommen und analysiert. Dies ist Grundlage für die Identifikation von Bewegungszuständen. Schließlich wird gezeigt, wie die in einer Verkehrssituation aufgenommen Signale in einer Laborumgebung reproduziert werden können, sodass die Identifikation der Bewegungszustände in einer Laborumgebung für Anwendungstests getestet werden kann. Dies ist für den Test von Navigationsanwendungen relevant, die Bewegungszustandsinformationen auf Basis von Inertialsignalen nutzen.




Abbildung 12: Vorgehensweise zur Identifikation von Bewegungszuständen und deren Simulation in einer Laborumgebung

3 Ein neues Verfahren zur Bewegungsklassifikation

In diesem Kapitel wird ein neues Verfahren zur Bewegungsklassifikation dargestellt. Grundlage sind die zunächst definierten Begriffe. Es folgen physikalische und messtechnische Systembetrachtungen zur Umsetzung eines solchen Systems. Anschließend werden Zustandsmodelle definiert, die für den Entwurf des Klassifikators nötig sind.

3.1 Begriffsdefinitionen

Diese Definitionen werden vereinbart:

Eine Bewegung ist eine Ortsveränderung im Raum. Fahrzeug-, Nutzer-, Sensorplattform- oder Trägerbewegungen sind Ortsveränderungen von Fahrzeugen, Nutzern, Sensorplattformen oder Trägern (letzterer ist ein Gegenstand oder ein Mensch, der eine Sensorplattform trägt). Gemeinsames Bezugssystem ist hier immer der Erdboden.

Befinden sich eine Person, eine Sensorplattform oder ein Träger in einem Fahrzeug, das sich bewegt, wird die zusammengesetzte Bewegung von Fahrzeug und Person, Sensorplattform oder Träger die jeweils resultierende Personen-, Sensorplattform-, oder Trägerbewegung genannt.

Die resultierende Sensorplattformbewegung kann sich somit aus Fahrzeug- und Trägerbewegung zusammensetzen, wobei die Trägerbewegung der Personenbewegung entsprechen kann.

Der Bewegungsmodus beschreibt die Art der Ortsveränderung einer Person, zu Fuß oder mittels eines Fahrzeugs.

Die Entscheidung für eine Art der Ortsveränderung wird in dieser Arbeit mit der Verkehrsmittelwahl zur Beförderung einer Person gleichgesetzt

Der Bewegungszustand gibt nun im Gegensatz zum Bewegungsmodus die detaillierte Bewegungsform während der Nutzung eines Bewegungsmodus an. Somit kann zum Beispiel für die verschiedenen menschlichen Bewegungsformen zu Fuß (in dieser Arbeit nachfolgend zusammengefasst unter dem biologischen Oberbegriff der Bipedie) zwischen Laufen und Gehen oder für die Fahrzeugbewegungszustände zwischen einer Kurvenfahrt und einer Geradeausfahrt unterschieden werden.

3.2 Systemperspektiven

Dieses Unterkapitel überträgt die physikalischen und messtechnischen Grundlagen aus Kapitel 2 auf das für diese Arbeit relevante Betrachtungsfeld der Klassifikation von Bewegungsmustern auf Basis von Messungen mittels mobiler Sensorplattformen innerhalb und außerhalb von Fahrzeugen.

3.2.1 Physikalische Betrachtung

In diesem Abschnitt werden die für diese Arbeit notwendigen Koordinatensysteme für eine anschließende Einbindung einer mobilen Sensorplattform in ein Fahrzeugmodell vorgestellt. Die Veröffentlichungen von Partzsch et al. (2012) und Partzsch et al. (2013b) sind Grundlage dieser Darstellungen.

3.2.1.1 Koordinatensysteme

Eine wesentliche Zielstellung dieser Arbeit ist der Rückschluss von Sensorplattformdaten auf den Bewegungszustand einer Person oder eines Fahrzeugs.

In diesem physikalischen System aus Untergrund, Fahrzeug, Person und Sensorplattform sind also vier Koordinatensysteme relevant, die in Abbildung 13 dargestellt sind:

- das erdfeste Koordinatensystem bei globaler Beobachtung von Fahrzeug und Person,
- das Fahrzeugkoordinatensystem
- das Körperkoordinatensystem und
- das Koordinatensystem einer Sensorplattform




Abbildung 13: Koordinatensysteme im betrachteten Kontext, nach Partzsch et al. (2013b)

Für diese Arbeit wird als Analyseausgangspunkt festgelegt, dass ein kalibriertes Signal im Fahrzeugkoordinatensystem bzw. im Körperkoordinatensystem mit gleicher Ausrichtung wie das Fahrzeugkoordinatensystem vorliegt. Dies ist keine Einschränkung des Verfahrens, da Methoden existieren, die ein solches Signal aus beliebigen Orientierungen zurückrechnen können

[Mizell 2003, Collin 2006]. Gegebenenfalls sind dazu weitere Sensoren, wie Drehraten-, Neigungswinkel- oder Magnetfeldsensoren nötig, die mittlerweile ebenfalls in handelsüblichen Smartphones integriert sind.

3.2.1.2 Bewegungsübertragungswege im betrachteten System aus Fahrzeug, Person und Sensorplattform

In den oben definierten Koordinatensystemen wird nun ein System betrachtet, das aus einem sich auf dem Erdboden bewegendem Fahrzeug, einer ebenfalls Erdbodenkontakt besitzenden (direkt oder indirekt durch das Fahrzeug) Person und einer Sensorplattform besteht. In diesem System entstehen, wie in den Abschnitten 2.2.2 bis 2.2.4 erläutert, an mehreren Stellen erzwungene Schwingungen. Diese werden durch den Kontakt der Systemkomponenten untereinander übertragen. Diese Übertragungspfade sind, wie in Abbildung 14 gezeigt, möglich:

- Szenario 1: Person trägt Plattform: Maßgebliche Schwingungen entstehen auf Grund der Körperbewegung beim Laufen oder bei einer Positionsveränderung, wie zum Beispiel dem Übergang vom Sitzen zum Stehen während des Aufstehens. Diese Schwingungen werden durch die Plattformverbindung zur Person auf die Plattform übertragen. Eine Verbindung kann durch Tragen der Plattform in der Kleidung oder in einem Gepäckstück oder am Körper (beispielsweise in der Hand) hergestellt werden.
- Szenario 2: Person nutzt Plattform: Maßgebliche Schwingungen entstehen in diesem Szenario durch die Körperbewegung der Person beim Laufen oder bei einer Positionsveränderung. Zusätzlich entstehen Schwingungen durch die Nutzung der Plattform, wie zum Beispiel durch Tippen oder zusätzliche Bewegungen.
- Szenario 3: Fahrzeug trägt Plattform: Maßgebliche Schwingungen entstehen durch den Fahrweg-Fahrzeug-Kontakt, den Antriebsstrang und den Luftwiderstand bei Bewegung des Fahrzeugs, wie im Abschnitt 2.2.3 erläutert. Weitere Schwingungen können durch die (mangelhafte) Befestigung der Sensorplattform entstehen.
- Szenario 4: Fahrzeug trägt Person, die Plattform trägt: Dieses Szenario ist eine Kombination aus Szenario 3 und Szenario 1. Maßgebliche Schwingungen entstehen somit auf Grund der Fahrzeugdynamik und den Körperbewegungen der die Sensorplattform tragenden Person.
- Szenario 5: Fahrzeug trägt Person, die Plattform nutzt: Dieses Szenario ist eine Kombination aus Szenario 3 und Szenario 2. Maßgebliche Schwingungen entstehen somit auf

Grund der Fahrzeugdynamik und den Körperbewegungen der die Sensorplattform tragenden Person zuzüglich der Schwingungen, die bei der Nutzung der Plattform entstehen.

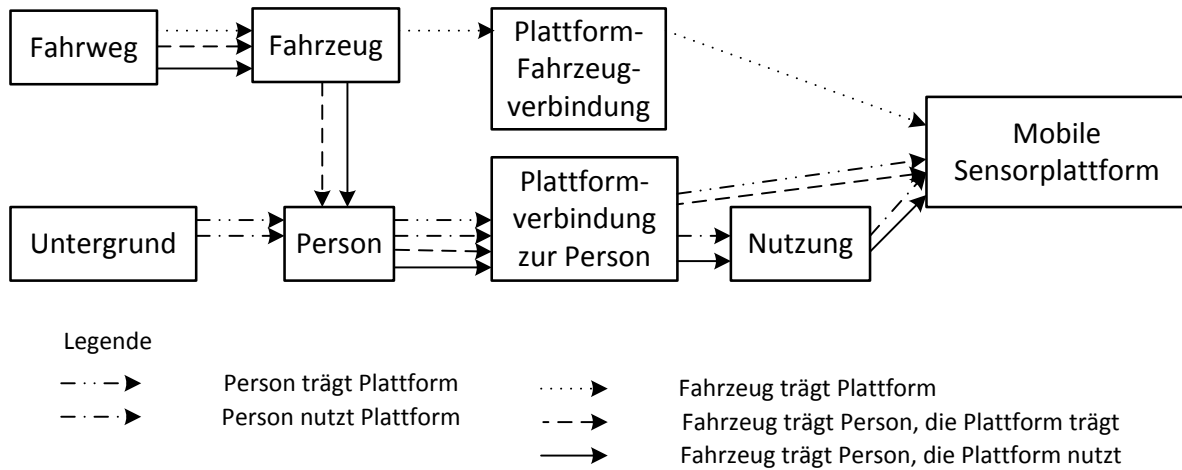


Abbildung 14: Übertragungswege der erzwungenen Schwingungen im betrachteten System

3.2.1.3 Systemparameter und Einflussmöglichkeiten

Wesentlichen Einfluss auf die Schwingungsübertragung haben die Systemparameter, die zum Teil technisch vorgegeben sind, zum Teil durch das Verhalten der im System befindlichen Personen (Plattformträger oder Fahrpersonal) beeinflusst werden können.

Abbildung 15 fasst die wesentlichen Systemkomponenten mit samt ihren technischen Systemeigenschaften, die vor der Beobachtung des Systems festgelegt worden sind und den Entscheidungen, die zur Beobachtungszeit getroffen werden, zusammen.

3.2.1.4 Schlussfolgerungen

Auf Basis der vorangegangenen Betrachtungen kann gefolgert werden, dass die interessierenden Fahrzeugbewegungen an mehreren Stellen auf dem Weg zur mobilen Sensorplattform gedämpft werden und dass Personenbewegungen sowie Bewegungen auf Grund einer Plattformnutzung die Fahrzeugbewegungen verdecken können.

Die im Rahmen dieser Arbeit durchgeführten Analysen beschränken sich auf das Szenario 3 als Referenzszenario zur Bestimmung der tatsächlichen Fahrzeugbewegung sowie den Szenarien 1 und 4 als Praxiszenarien für den Einsatz einer von einer Person getragenen Sensorplattform. Eine dezidierte Analyse von Plattformbewegungen durch Nutzung ist nicht Gegenstand dieser Arbeit, wurden in [Partzsch 2013b] diskutiert.

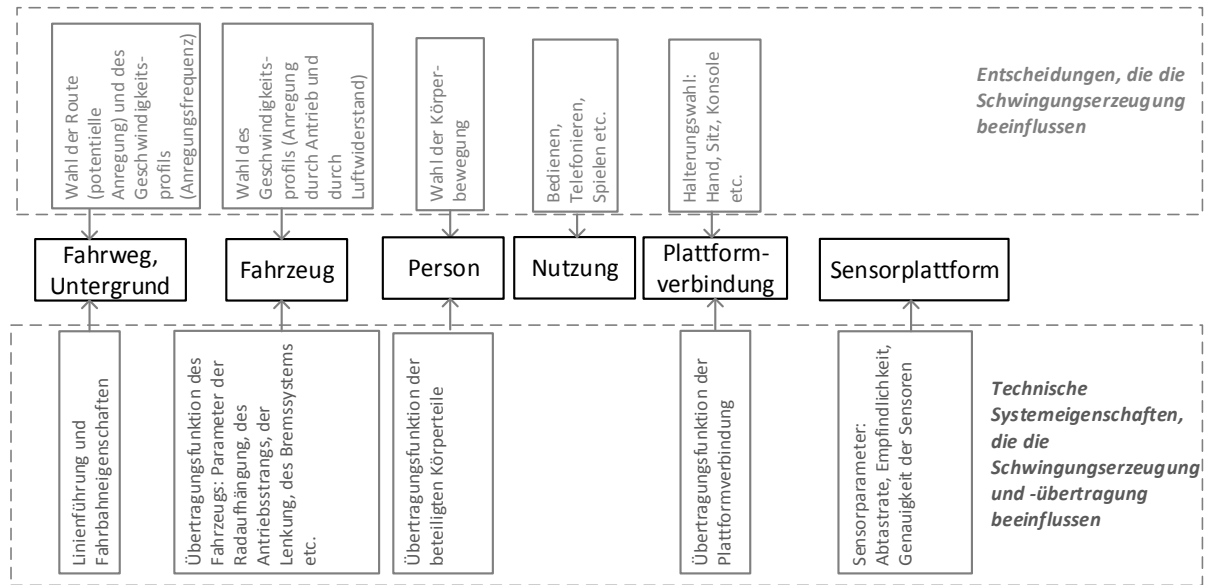


Abbildung 15: Vordefinierte und veränderliche Systemparameter (in Anlehnung an [Partzsch et al. 2013c])

3.2.2 Messtechnische Betrachtung

Dieser Abschnitt überträgt die physikalische Betrachtung aus dem vorangegangenen Abschnitt in die Messtechnik. Notwendige Sensoreigenschaften werden für das vorliegende Messsystem diskutiert.

3.2.2.1 Messsystem

Abbildung 16 stellt das für diese Arbeit konzipierte Messsystem dar. Das zu beobachtende System besteht aus Systemkomponenten, die Schwingungen erzeugen und dämpfen können und deren mögliche Schnittstellen. Als relevante Messobjekte werden im Rahmen dieser Arbeit die Bewegung von Fahrzeug, Person und Sensorplattform betrachtet.

Mittels geeignet platzierter Sensorik können somit die Beschleunigungen von Fahrzeug, Person und Plattform als Messsignal ermittelt werden. Je nachdem, wo die Plattform platziert ist, korreliert das Messsignal, das mittels Sensorplattform gemessen werden kann mit der Fahrzeug- und/oder der Personenbeschleunigung.

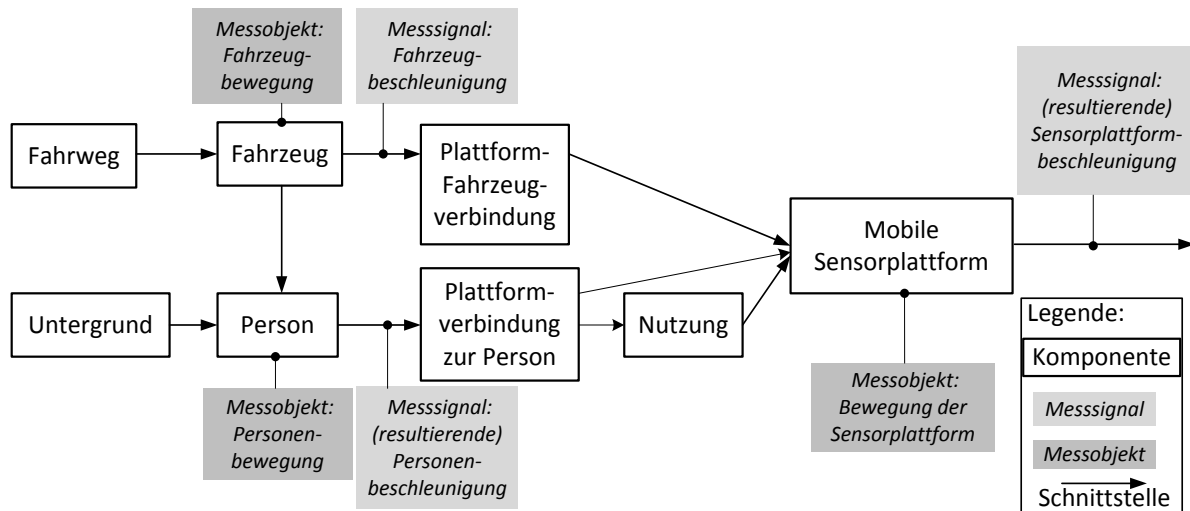


Abbildung 16: Messobjekte im Systemkonzept zur Aufnahme von Fahrzeugbewegungsmustern mittels mobiler Sensorplattform

3.2.2.2 Benötigte Sensoreigenschaften

Im Abschnitt 2.3.2 wurden nach Fraden (2010) Kriterien zur Auswahl eines (Beschleunigungs-) Sensors aufgestellt, denen für die hier durchgeführte Messaufgabe nun konkreten Anforderungen gegenübergestellt werden:

- **Sensitivität:** Da der Sensor eine gute Aussteuerung ermöglichen soll, wird entsprechend der Fahrzeugdynamik ein Wertebereich von $\pm 2g$ benötigt.
- **Übertragungsfunktion:** Der Sensor soll entsprechend der zu erwartenden Fahrzeugdynamik die Messung des Gleichanteils und niederfrequente Schwingungen (bis 200 Hz) ermöglichen.
- **Resonanzfrequenz:** Der Sensor muss auf Grund der geforderten Übertragungsfunktion eine Resonanzfrequenz von deutlich über 200 Hz besitzen.
- **Nullpunktfehler:** Weist der Sensor einen Nullpunktfehler auf, kann dieser Fehler nachträglich korrigiert werden. Der Fehler ist somit im Rahmen dieser Arbeit tolerierbar.
- **Linearität:** Der Sensor sollte für den Temperaturbereich typische europäischer Außentemperaturen (0 bis 30°C – Plattform in Kleidung am Körper oder in klimatisiertem Fahrzeug) eine lineare Kennlinie aufweisen.

Bei dem Entwurf eines Klassifikators für Bewegungszustände ist darauf zu achten, dass diese Anforderungen seitens der Sensoren und angeschlossener Signalverarbeitungssysteme erfüllt werden.

Zur Bewertung der Tauglichkeit einer mobilen Sensorplattform kann gemäß [DIN ISO16063-21] ein hinsichtlich der Messgenauigkeit höherwertiges, fahrzeugfixiertes Referenzmesssystem genutzt werden.

3.3 Zustandsmodelle

Dieses Unterkapitel erarbeitet das für eine Klassifikation mittels HMM nötige Zustandsmodell und baut damit auf den Grundlagen von Unterkapitel 2.4 auf. Die im Abschnitt 2.4.2 diskutierten multimodalen Reiseketten bilden die Grundlage für das geschichtete Zustandsmodell, das zunächst überblicksmäßig dargestellt wird. Die anschließenden Unterkapitel entwerfen notwendige Modelluntereinheiten zur Detaillierung des Gesamtsystems.

3.3.1 Geschichtetes Zustandsmodell

Vergleichbar mit dem Vorgehen von Lee et al. (2011) wird ein zweischichtiges Zustandsmodell zur Unterscheidung des globalen Bewegungsmodus (bei Lee et al. (2011) state) sowie der detaillierten Bewegungszustände (bei Lee et al. (2011) activity) aufgebaut. Die nachfolgende Modellierung beschränkt sich auf Grund der Fokussierung auf Bewegungszuständen im öffentlichen Personenverkehr auf die Zugangsform Bipedie und die Fahrzeugarten Bus und Straßenbahn.

Für die spätere Umsetzung des Klassifikationsproblems als ein HMM mit Modelluntereinheiten werden weitere Zustandsschichten definiert, die in Abbildung 17 dargestellt sind.

Das Modell besteht aus zwei Schichten:

- Schicht 1 zur Unterscheidung der Bewegungsmodi:
Diese wird verwendet um die prinzipielle Art der Fortbewegung zu unterscheiden. Es können beliebige Fahrzeugtypen in die Überlegung einbezogen werden. Die Arbeit beschränkt sich auf die Modi: „Ruhe“, „Bipedie“, „Bus“ und „Straßenbahn“. „Ruhe“ ist Fahrzeugtyp-übergreifend definiert. Sie kann während der Fahrzeugbenutzung (Halt des Fahrzeugs) und bei der Bewegung zu Fuß (ruhiger Stand) auftreten.
- Schicht 2 zur Unterscheidung der Bewegungszustände: Hier wird für jeden Modus eine Modelluntereinheit zur Beschreibung der detaillierten Bewegungsart während der Nutzung eines Bewegungsmodus gebildet. Eine Modelluntereinheit kann aus mehreren Subuntereinheiten bestehen, wenn dies zur Beschreibung der Bewegung auf Grund der unterschiedlichen zeitlichen und räumlichen Dimensionen nötig ist.

Dieses zweischichtige Vorgehen samt detaillierter Zustandsdiagramme stellt eine deutliche Erweiterung gegenüber dem Stand der Wissenschaft dar (vgl. [Bocksch et al. 2013], [Mannini et al. 2010]).

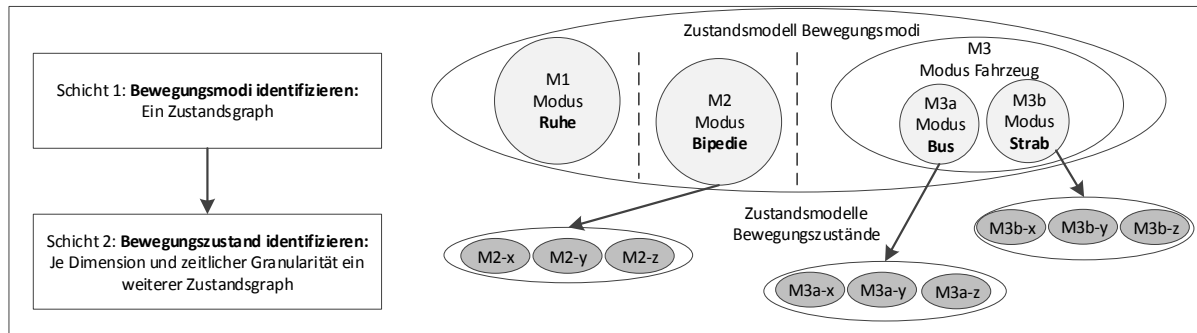


Abbildung 17: geschichtetes Zustandsmodell

3.3.2 Bewegungsmodi und -zustände

Die erste Schicht besteht aus den Modi „Ruhe“ (M1), „Bipedie“ (M2) und dem Fahrzeugmodus (M3), der im Rahmen dieser Arbeit auf die beiden Fahrzeugtypen „Bus“ (M3a) und „Straßenbahn“ (M3b, abgekürzt in den Abbildungen mit Strab) beschränkt wird. Eine Erweiterung um weitere Fahrzeugtypen ist uneingeschränkt möglich.

Zur Vernetzung der Modi wird das in Abbildung 18 dargestellte Zustandsmodell festgelegt. Ausgehend von den Modi „Ruhe“ und „Bipedie“ sind alle anderen Modi erreichbar. Ein direkter Übergang zwischen den Fahrzeugmodi ist nicht vorgesehen.

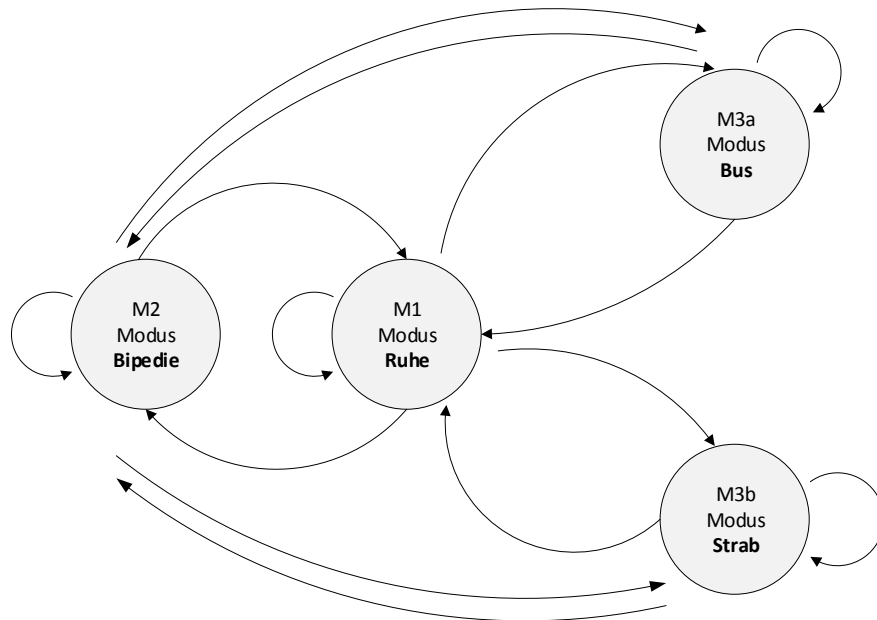


Abbildung 18: Zustandsgraph zur Unterscheidung der Bewegungsmodi

Nachfolgend werden für die einzelnen Bewegungsmodi weitere detaillierte Personen- und Fahrzeugbewegungszustände definiert, die als ein Zustandsgraph mit einander verknüpft sind.

3.3.2.1 Ruhe (M1)

Es gibt verschiedene Positionen des Nutzermediums und der Person, die als „Ruhemodus“ zu bezeichnen sind. So kann die Person ruhig stehen oder sitzen, oder das Nutzermedium liegt auf einer Unterlage, die nicht bewegt wird, wie zum Beispiel ein Tisch in einer Wohnung oder eine Oberfläche in einem stehenden Fahrzeug. In diesem Sinn können zwar Zustände definiert werden, Zustandsübergänge sind ohne eine Bewegung des Nutzermediums nicht möglich.

Im Rahmen dieser Arbeit wird daher der Ruhemodus nicht weiter differenziert.

3.3.2.2 Bipedie (M2)

Relevante Personenbewegungszustände im Kontext eines logischen Map Matchings sind unterschiedliche Formen der Bipedie, wie Gehen, Laufen und Treppensteigen auf-/abwärts. Diese können, wie in Abbildung 19 gezeigt, mit einander verknüpft werden. Es ist also möglich, von den Bewegungszuständen „Gehen“ und „Laufen“ alle anderen Zustände zu erreichen. Zwischen den beiden Richtungen des Treppensteigens ist kein direkter Übergang möglich, da zu erwarten ist, dass zwischen diesen beiden Zuständen entweder eine weitere Laufpassage (Gang zur nächsten Treppe) oder ein Richtungswechsel ohne Fortbewegung in der Ebene liegt.

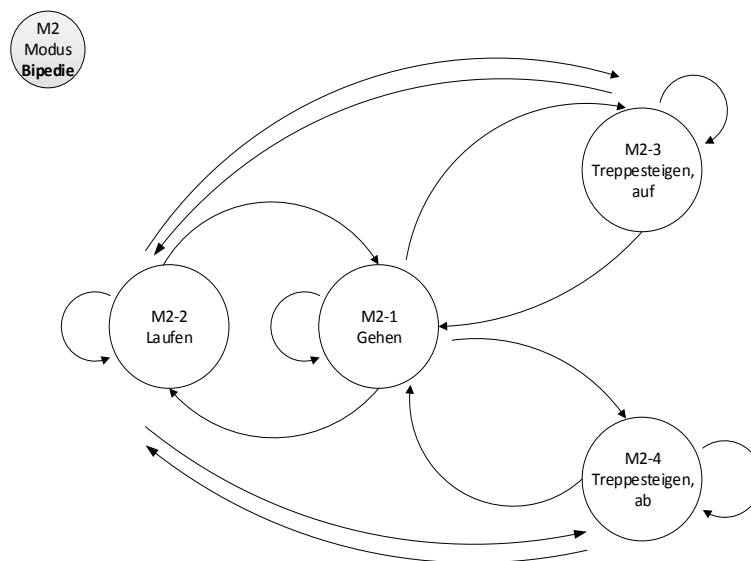


Abbildung 19: Zustandsgraph zur Unterscheidung der Personenbewegungszustände als Detaillierung für Bewegungsmodus „Bipedie“ (M2)

3.3.2.3 Fahren (M3)

Für die beiden Bewegungsmodi „Bus“ (M3a) und „Straßenbahn“ (M3b) können folgende weitere Zustandsgraphen zur detaillierten Beschreibung der Bewegung definiert werden. In diesem Ab-

schnitt werden die Modellteile für den Bewegungsmodus Bus vorgestellt. Die prinzipielle Übertragbarkeit dieses Modells auf den Bewegungsmodus „Straßenbahn“ wird im letzten Absatz dieses Unterkapitels diskutiert.

3.3.2.4 Submodelluntereinheiten für den Bewegungsmodus „Bus“ (M3a)

Aus der Motivation des logischen Map Matchings heraus ist es sinnvoll, typische Bewegungszustände während der Bewegung entlang einer Trajektorie zu erkennen. So ist z. B. für schienengebundene Systeme (U-Bahn, S-Bahn etc.) ein Halt lediglich an Haltestellen oder Bahnhöfen wahrscheinlich. Weiterhin können Informationen über Kurven und Untergründe (Weichen, Kopfsteinpflaster oder allgemein schlechter Straßenzustand, Dehnungsfugen an Brückenbauwerken) wertvolle Fingerabdrücke liefern, die zur Verortung eines Fahrzeugs mittels eines bekannten Zustandskatalogs genutzt werden können.

Für den Bewegungsmodus „Bus“ werden auf Basis der drei orthogonalen Sensorachsen sowie eines möglichen Zeitbezugs diese vier Submodelluntereinheiten definiert:

- für die Bewegungszustände, die sich anhand des Signals in x -Richtung klassifizieren lassen,
- für die Bewegungszustände, die sich anhand des Signals in y -Richtung klassifizieren lassen
- für die Bewegungszustände, die sich anhand des Signals für einen kurzen Zeithorizont in z -Richtung klassifizieren lassen, und
- für die Bewegungszustände, die sich anhand des Signals für einen langen Zeithorizont in z -Richtung klassifizieren lassen.

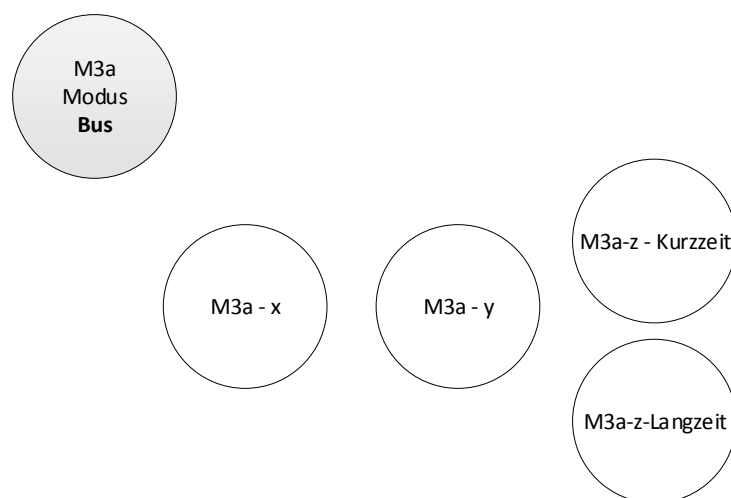


Abbildung 20: Achsenbezogene Bewegungszustände als Detaillierung für den Bewegungsmodus „Bus“ (M3a)

3.3.2.5 Bewegungszustände entlang der Fahrtrichtung (x-Achse) eines Fahrzeugs

Beschleunigungen, die in Fahrtrichtung eines Fahrzeugs gemessen werden können, bezeichnet mit a_x , sind mit diesen Bewegungszuständen gekoppelt:

- positiv Beschleunigen ($a_x > 0$, Fahrzeuggeschwindigkeit $v > 0$ und $\Delta v > 0$),
- Beharren ($a_x = 0$, Fahrzeuggeschwindigkeit $v > 0$ und $\Delta v = 0$),
- negativ Beschleunigen ($a_x < 0$, Fahrzeuggeschwindigkeit $v > 0$ und $\Delta v < 0$),
- Haltevorgang ($a_x = 0$, Fahrzeuggeschwindigkeit $v = 0$).

Diese Bewegungszustände können in einem Zustandsmodell, wie in Abbildung 21 gezeigt, verknüpft werden. Die ersten drei Bewegungszustände „positiv Beschleunigen“, „Beharren“ und „negativ Beschleunigen“ sind vollständig mit einander verbunden. Der Haltevorgang ist ausgehend vom Zustand „negativ Beschleunigen“ zu erreichen. Wird direkt nach dem vollständigen Stoppen beschleunigt, wird der Zustand „positiv Beschleunigen“ erreicht. Andernfalls wird in den Modus „Ruhe“ gewechselt, der außerhalb dieses Modells liegt.

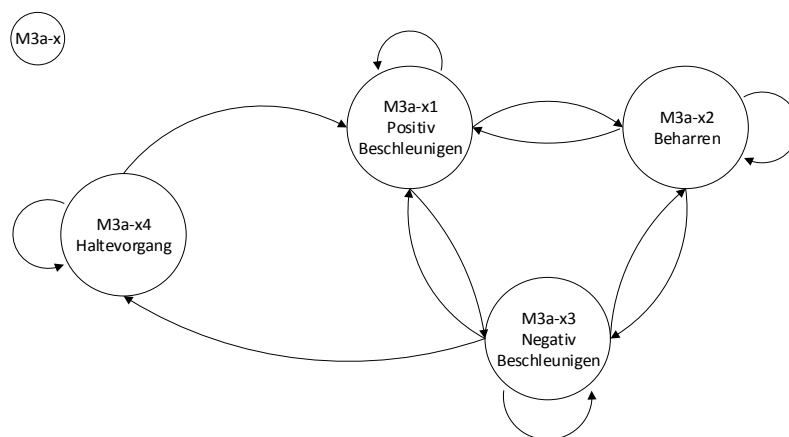


Abbildung 21: Zustandsgraph für Bewegungszustände in x-Richtung eines Signals als Detaillierung für den Bewegungsmodus „Bus“ (M3a)

3.3.2.6 Bewegungszustände entlang der y-Achse eines Fahrzeugs

Auf Basis der Beschleunigungen, die entlang der y-Achse eines Fahrzeugs gemessen werden (bezeichnet mit a_y), und deren Beschleunigungsänderungen, können drei weitere Fahrzeugbewegungszustände definiert werden:

- Geradenfahrt ($a_y = 0$)
- Kurvenfahrt – Linkskurve ($a_y < 0$)
- Kurvenfahrt – Rechtskurve ($a_y > 0$)

Diese Zustände können, wie in Abbildung 22 gezeigt, vollständig miteinander verbunden werden.




Abbildung 22: Zustandsgraph für Bewegungszustände in y -Richtung eines Signals als Detaillierung für den Bewegungsmodus „Bus“ (M3a)

3.3.2.7 Bewegungszustände entlang der z -Achse eines Fahrzeugs

Analog zu den Beschleunigungen a_x und a_y , können für den Beschleunigungsanteil in z -Richtung, bezeichnet mit a_z , Bewegungszustände definiert werden. Wegen des messbaren Effekts der Gravitation in dieser Achse wird vorgeschlagen, zwei Zeitgranularitäten auszuwerten:

- Kurzzeit-Bewegungszustände zur Bewertung der Vibration in der z -Ebene
- Langzeit-Bewegungszustände zur Bewertung der Achsenverschiebung durch An- oder Abstiege in der Fahrbahn: hierbei kann der Effekt ausgenutzt werden, dass sich das Fahrzeugkoordinatensystem gegen das der Erde verdreht und somit der Anteil der messbaren Gravitation zwischen der z - und der x -Achse wandert.

Für ein logisches Map Matching sind auf Basis der gemessenen Vibration diese Zustände hilfreich:

- Fahrt über glatten Untergrund (zum Beispiel frisch verlegter Asphalt),
- Fahrt über unebenen Untergrund (zum Beispiel Kopfsteinpflaster oder alter Asphaltfahrbahnbelag mit Reparaturstellen oder Setzungen).

Beide Zustände können, wie in Abbildung 23 gezeigt, direkt in einander übergehen.




Abbildung 23: Zustandsgraph für Kurzzeit-Bewegungszustände in z -Richtung eines Signals als Detaillierung für den Bewegungsmodus „Bus“ (M3a)

Neben diesen Kurzzeit-Bewegungszuständen ist die langfristige Verschiebung des Offsets in der z -Achse interessant, da diese Rückschlüsse über das Höhenprofil der Fahrbahn geben kann. Somit sind weitere drei Bewegungszustände prinzipiell auswertbar:

- Bergfahrt
- Talfahrt
- Ebenenfahrt

Diese Zustände können, wie in Abbildung 24 gezeigt, direkt in einander übergehen.




Abbildung 24: Zustandsgraph für Langzeit-Bewegungszustände in z -Richtung eines Signals gemessen in einem Bus

Zur Darstellung einer Fahrt über eine Kuppe werden somit die Zustände: Bergfahrt und Talfahrt aneinandergereiht. Gegebenenfalls existiert für die Dauer des Übergangs der Zustand Ebene. Eine Senke könnte so dargestellt werden: Talfahrt – (je nach Dauer des Übergangs: Ebene) – Bergfahrt.

3.3.2.8 Submodelluntereinheiten für den Bewegungsmodus „Straßenbahn“ (M3b)

Für die Straßenbahn kann eine vergleichbare Schicht zur Beschreibung von Straßenbahnbewegungszuständen konstruiert werden, wie in Anhang A abgebildet. Die Teilgraphen für x - und y -Richtung können komplett übernommen werden. In z -Richtung ist eine inhaltliche Anpassung nötig: Hier wird in Weichen-/Kreuzungsfahrt und Fahrt außerhalb des Weichen-/Kreuzungsbereiches unterschieden. Die Unterscheidung zwischen Berg- und Talfahrt ist weiterhin möglich.

3.4 Klassifikatorentwurf

Die im Unterkapitel 2.6 vorgestellten Methoden zur Signalklassifikation werden in diesem Unterkapitel auf das vorliegende Problem der Klassifizierung von Beschleunigungssignalen angewandt.

Es werden nun das entworfene Gesamtsystem vorgestellt und die Teilschritte der Vorverarbeitung, der Merkmalsauswahl und des Klassifikatoraufbaus präzisiert.

3.4.1 Systemübersicht

Nach Hoffmann (1998) kann das vorliegende Problem mit Hilfe eines Signalerkennungssystems gelöst werden. Dieses besitzt die in Abbildung 25 dargestellten Bausteine. Es ist somit die Erweiterung der informationstechnischen Interpretation der Messkette aus Abschnitt 3.2.2 um ein Erkennungssystem bestehend aus einem Analysator, der Merkmale aus den gemessenen Beschleunigungen extrahiert und einem Klassifikator, der die Merkmale bewertet und eine Entscheidung zu einer Klassenzugehörigkeit zu einem Bewegungsmodus oder eines Bewegungszustandes trifft.

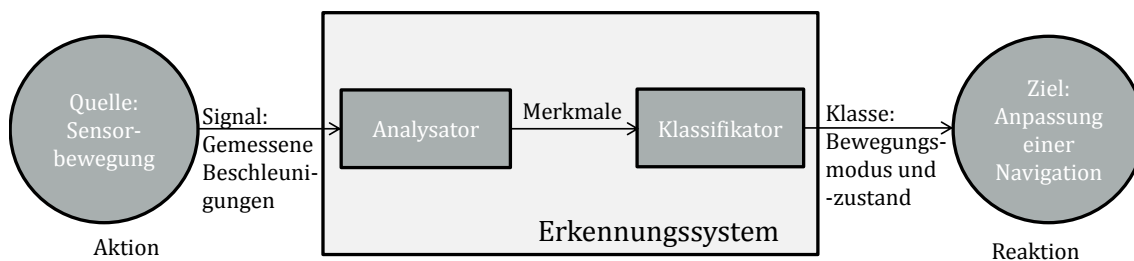


Abbildung 25: Aufbau des Signalerkennungssystems zur Bewegungsidentifikation (in Anlehnung an [Hoffmann 1998])

Die Signalverarbeitung verläuft gemäß der im Abschnitt 2.6.1 vorgestellten Schritte. Auf die Klassifikation von Beschleunigungssignalen angewandt, erfolgt der Prozess wie in Abbildung 26 dargestellt. Wesentliche Schritte sind nach der Messung der Signale die Vorverarbeitung, die Identifizierung von effektiven Merkmalen, und der Aufbau eines Klassifikators.

Die Umsetzung dieser Schritte erfolgt im Kapitel 4 für ausgewählte Szenarien.

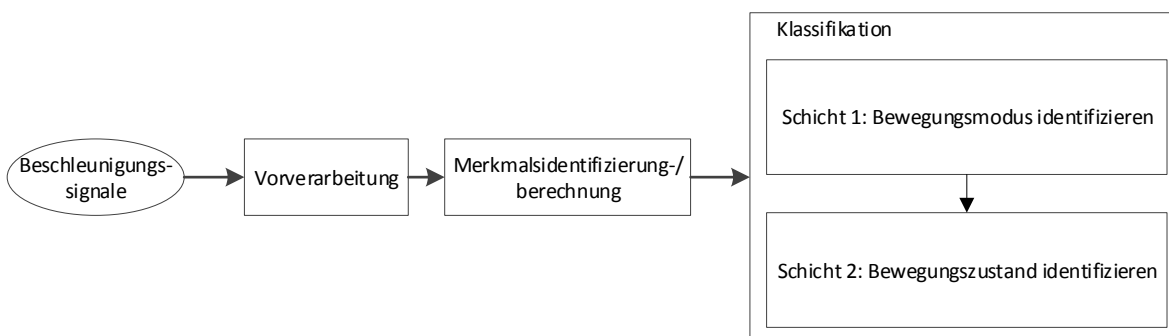


Abbildung 26: Ablauf der Signalklassifikation

3.4.2 Vorverarbeitung

Im Abschnitt 2.6.2 sind allgemeine Methoden der Datenvorverarbeitung dargestellt worden. In diesem Abschnitt werden diese Methoden auf die in dieser Arbeit zu lösende Aufgabe übertragen.

3.4.2.1 Screening und Plausibilisierung

Zur Plausibilisierung der gemessenen Daten wird im Rahmen dieser Arbeit dieser Ansatz verfolgt:

- Überprüfung der Einhaltung der Sensorspezifikationen durch Probemessungen in Ruhe (Labor oder stehendes Fahrzeug)
- Visuelle Prüfung der aufgenommenen Daten auf Basis von Erfahrungswerten

Darüber hinaus ist es möglich, eine automatisierte Ausreißeridentifikation z. B. über den Vergleich von Verteilungen zu verwenden.

3.4.2.2 Datenintegration

Der Vorverarbeitung der gemessenen Beschleunigungssignale kommt dann Bedeutung zu, wenn Signale aus mehreren Quellen gemeinsam analysiert werden sollen. In diesem Fall müssen die Signale im Vorfeld zeitlich synchronisiert und eine einheitliche Abtastfrequenz mittels Abtastratenumsetzung herbeigeführt werden.

3.4.2.3 Koordinatentransformation und Kalibrierung

Wie im Abschnitt 3.2.1 diskutiert, können bei der Messung in einem Fahrzeug je nach Platzierung der Sensorplattform verschiedene Koordinatensysteme auftreten. Gegebenenfalls ist eine Überführung eines Koordinatensystems in ein anderes notwendig. Im Rahmen dieser Arbeit wird durch eine geeignete Ausrichtung der Sensoren darauf verzichtet, die Signale und deren Koordinatensysteme nachzuführen. Zu Beginn einer Auswertung werden die Achsen passend ausgerichtet.

Es existieren Methoden zur Bestimmung der Orientierung, [Mizell 2003, Collin 2006, Welch et al. 2013], die gegebenenfalls weitere Sensoren, wie Drehraten- oder Magnetfeldsensoren, benötigen. Diese Ansätze sind mittlerweile in handelsüblichen Smartphones integriert.

Auf Grund der Temperaturabhängigkeit der Sensoren ist in jedem Fall eine Nullpunkt-Korrektur notwendig. Dies kann zum Beispiel durch die Entfernung des Mittelwertes im Stand geschehen.

3.4.3 Klassifikation

Auf Basis der vorverarbeiteten Signale können nun Merkmale extrahiert werden, die die Grundlage für eine Signalklassifikation bilden. Die Bewertung des Klassifikators schließt diesen Prozess ab.

3.4.3.1 Merkmalsextraktion

Der erste Schritt zu gut trennenden Merkmalen ist eine umfassende Signalanalyse, deren Methoden überblicksmäßig im Unterkapitel 2.5 dargestellt wurden. Diese Signalanalyse ist die Basis für eine Merkmalsextraktion und -verdichtung, vorgestellt im Abschnitt 2.6.3. Ziel ist es somit, aus der Menge signalanalytisch möglicher Merkmale diejenigen charakteristischen Merkmale auszuwählen, die die im Kapitel 3.3 vorgestellten Bewegungszustände und Bewegungsmodi bestmöglich unterscheidbar machen.

Diese, für Aufgaben dieser Art in der Literatur übliche, Merkmale für Fahrzeug- und Personenbewegungszustände, sowie Bewegungsmodi werden extrahiert und auf Basis ihrer statistischen Eigenschaften auf ihren Informationsgehalt für die Klassifikation bzw. ihre Redundanz untersucht.

- | | |
|--|--|
| 1. Mittelwert | 11. Schiefe |
| 2. Median | 12. Mittelwert der Signalquadrate |
| 3. Modalwert | 13. Nulldurchgänge |
| 4. Spannweite | 14. Mittlere Prominenz der lokalen Maxima |
| 5. Minimum | 15. Wavelet-Koeffizientensumme |
| 6. Maximum | 16. Absolute Differenz zwischen Anfangs- und Endwert |
| 7. Varianz | 17. Frequenz maximaler Amplitude |
| 8. Standardabweichung | 18. FFT-Koeffizientensumme, auch Teilsumme für ausgewählte Koeffizienten |
| 9. Variationskoeffizient | 19. FFT-Koeffizientenquadrate-Summe |
| 10. Mittlere absolute Abweichung des Medians | |

Für die vorliegende Aufgabe wurde ein Beobachtungsintervall von einer Sekunde verwendet, da Voruntersuchungen gezeigt haben, dass bei dieser Fensterung der instationären Signale von quasi-statischen Signalen ausgegangen werden kann. Ein Merkmal, das auf der Wavelet-Analyse basiert (z.B. Nr. 15) wird in dem Fall des gefensterten Signals nicht die Stärke der Wavelet-Analyse für instationäre Signale beweisen können. In der Aussage gleicht sich das Ergebnis mit einem FFT-basierten Merkmal. Um die Vielfalt an Merkmalen zu zeigen, wurde dennoch ein Merkmal in die heuristische Auswahl für diese Arbeit aufgenommen.

Mit Blick auf verfügbare Ressourcen (verfügbare Rechenzeit, -kapazität) kann es sinnvoll sein, sich auf wenige aussagekräftige Merkmale zu begrenzen. Eine Merkmalsauswahl könnte beispielsweise so erfolgen:

- Berechnung der Korrelationskoeffizientenmatrix für alle betrachteten Merkmale

- Betrachtung des ersten Merkmals (erste Zeile) und Streichung der Spalten mit Korrelationskoeffizienten, die betragsmäßig größer als ein Schwellwert, zum Beispiel 0,5 sind
- Fortsetzung für alle weiteren Merkmale (weitere Zeile).

Auf diese Weise erhält man auf schnelle Weise einen reduzierten Merkmalsraum mit linear nur wenig abhängigen Komponenten.

3.4.3.2 Klassifikatorstruktur

Wie dargestellt, wird der Klassifikator zwei Schichten besitzen: eine Schicht zur Identifizierung von Bewegungsmodi und eine Schicht zur Identifizierung der detaillierten Bewegungszustände.

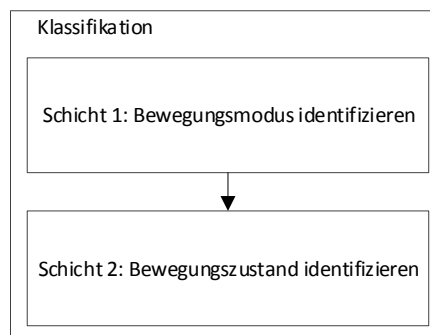


Abbildung 27: Klassifikationsschritt

Innerhalb beider Schichten werden nun insgesamt vier Klassifikatorvarianten vergleichend implementiert, deren theoretische Grundlagen in den Abschnitten 2.6.4 und 2.6.5 aufgezeigt wurden:

- heuristischer Entscheidungsbaum
- heuristischer Entscheidungsbaum mit Hidden Markov Model-Filterung
- Diskriminanzanalyse-Klassifikator
- Diskriminanzanalyse-Klassifikator mit Hidden Markov Model-Filterung

3.4.3.3 Vorgehensweise zur Erstellung des heuristischen Entscheidungsbaums

Zunächst erfolgt die Merkmalsauswahl relevanter Entscheidungskriterien aus der Menge aller berechneten Merkmale nach der in Abschnitt 3.4.3.1 vorgeschlagenen Vorgehensweise.

Für die Bestimmung der einzelnen Entscheidungskriterien, das heißt, der Schwellwerte, wurde folgendes Vorgehen je Datensatz (Messstraßenbahndaten, Sensorplattformdaten der Bewegungsmodi Straßenbahn, Bus und Bipedie) verwendet:

- Sukzessiver Aufbau des Entscheidungsbaums mit linear unabhängigen Merkmalen

- Initiale Festlegung des betrachteten Schwellwertes anhand der Datenanalyse
- Numerisches Testen des Schwellwertes anhand der Verwechslungsmatrix, so, dass die Korrektheit des Klassifikationsergebnisses bezogen auf den Datensatz maximal ist.

Der heuristische Entscheidungsbaum ermöglicht eine Klassifikation auf Grundlage weniger Merkmale und zeigt damit das Ergebnis einer Merkmalsverdichtung und -gewichtung: verwendete Merkmale haben das Gewicht 1, während nicht verwendete Merkmale das Gewicht 0 besitzen. Prinzipiell sind Werte zwischen 0 und 1 möglich.

3.4.3.4 Erstellung von Diskriminanzanalyse-Klassifikator und HMM-Filter

Zur Erzeugung der Diskriminanzanalyse-Klassifikatoren und der Hidden Markov Model (HMM)-Filter wurde auf die Statistics and Machine Learning Toolbox von MATLAB zurückgegriffen. In dieser Toolbox existieren Funktionen zur automatischen Generierung von linearen oder quadratischen Klassifikatoren auf Basis von Beobachtungen und deren Anwendung auf neue Daten. Ebenfalls stellt diese Toolbox vorgefertigte Funktionen zum Anlernen und Verwenden eines HMM-Filters bereit.

Für die Untersuchungen in Kapitel 4 wurden je Datensatz (Messstraßenbahndaten, Sensorplattformdaten der Bewegungsmodi Straßenbahn, Bus und Bipedie) eine Merkmalsmatrix erzeugt, die die in Abschnitt 3.4.3 aufgeführten Merkmale für jedes Sekundenintervall enthält. Anschließend wurde je Signalachse ein linearer und ein quadratischer Klassifikator erzeugt. Für alle Klassifikatoren einschließlich der heuristischen Entscheidungsbäume wurden darüber hinaus die Transmissions- und die Emissionsmatrix zur HMM-Filterung erzeugt.

3.4.3.5 Klassifikatorbewertung

Die Bewertung der vorliegenden Klassifikatorstrukturen erfolgt anhand der Einschätzung von Trainings- und Generalisierungsfehler auf Basis der Verwechslungsmatrix, siehe Formel (14) im Abschnitt 2.6.6. Als Trainingsfehler werden diejenigen Fehlklassifikationen bewertet, die entstehen, wenn die Lerndatenbasis gleichzeitig die Testdatenbasis ist. Dem gegenüber steht der Generalisierungsfehler. Unter diesem Begriff werden diejenigen Fehlklassifikationen zusammengefasst, die entstehen, wenn zum Testen eine von der Lerndatenbasis verschiedene Testdatenbasis verwendet wird.

Die Wirksamkeit der im Rahmen dieser Arbeit betrachteten Klassifikatoren wird mit der Klassifikationsgüte folgender drei naiver Klassifikatorstrategien verglichen:

- naiver Klassifikator 1: Dieser Klassifikator zieht eine zufällige Ausgabeklasse, wobei die Entscheidung für eine der K Ausgabeklassen gleichverteilt ist. Die Wahrscheinlichkeit einer korrekt vorhergesagten Klasse kann mit Hilfe der Anzahl an Klassen K berechnet werden mit

$$P_{\text{kor}, \text{N1}} = 1/K. \quad (15)$$

- naiver Klassifikator 2: Dieser Klassifikator zieht eine zufällige Ausgabeklasse unter der Annahme, dass die Wahrscheinlichkeit der Ausgabeklassen $P_{\text{ist}, i}$ bekannt ist. Die Wahrscheinlichkeit einer korrekt vorhergesagten Klasse kann dann berechnet werden mit

$$P_{\text{kor}, \text{N2}} = \sum_{i=1}^K P_{\text{ist}, i}^2. \quad (16)$$

Diese Summe fasst damit die Wahrscheinlichkeiten derjenigen möglichen Ereignisse zusammen, bei denen die vom Klassifikator gewählte Ausgabeklasse mit der tatsächlichen Klasse übereinstimmt. Sie ist damit immer kleiner oder gleich 1.

- naiver Klassifikator 3: Dieser Klassifikator zieht immer diejenige Ausgabeklasse mit der maximalen Wahrscheinlichkeit P_{max} . Die Wahrscheinlichkeit einer korrekt vorhergesagten Klasse beträgt dann

$$P_{\text{kor}, \text{N3}} = P_{\text{max}}. \quad (17)$$

Es kann nachgewiesen werden (siehe Anhang B), dass beim Vergleich der Klassifikationsgüten aller drei naiver Klassifikatoren die Ungleichung gilt:

$$P_{\text{kor}, \text{N1}} \leq P_{\text{kor}, \text{N2}} \leq P_{\text{kor}, \text{N3}}. \quad (18)$$

Klassifikator 3 ist somit immer der beste. Seine Wahrscheinlichkeit für die Korrektheit ist, wie oben diskutiert P_{max} . Ein Klassifikator ist also dann wirksam, wenn die auf Basis der Ausgabehäufigkeiten approximierte Wahrscheinlichkeit einer korrekten Klassifikation größer ist als die größte Auftrittswahrscheinlichkeit P_{max} der zugrundeliegenden Klassen.

4 Empirische Untersuchungen zur Bewegungsklassifikation

Dieses Kapitel erläutert die Umsetzung des im Kapitel 3 beschriebenen Verfahrens zur Klassifikation von Beschleunigungsmustern. Zunächst werden die Versuchsrandbedingungen einschließlich der Untersuchungsziele, verwendeten Messsysteme und durchgeführten Messkampagnen dargestellt. Die anschließenden Abschnitte diskutieren die Ermittlung der Teilmodelle zur Klassifikation.

4.1 Versuchsrandbedingungen

Dieses Unterkapitel erläutert die Versuchsrandbedingungen mit den Untersuchungszielen, der Darstellung der verwendeten Messsysteme und der durchgeführten Messkampagnen.

4.1.1 Untersuchungsziele

Cherkassky et al. (2007) schlagen zur Entwicklung von Klassifikatoren diese Verfahrensweise vor:

1. Feststellung des Problems,
2. Formulierung der Hypothese,
3. Entwurf des Versuchsablaufs,
4. Generierung und Vorverarbeitung der Daten,
5. Schätzung des Modells,
6. Interpretation und Diskussion des Modells.

Dieser Untersuchungsmethodik folgend wird nun gemäß Schritt 1 ein System aufgebaut, das in der Lage ist, anhand von, mittels mobiler Sensorplattformen gesammelter, Beschleunigungsmustern Bewegungsmodi und Bewegungszustände zu unterscheiden.

Gemäß Schritt 2 ist somit die Hypothese zu bestätigen, dass auf Basis von solchen Beschleunigungsmustern Bewegungsmodi und Bewegungszustände unterschieden werden können.

Abschnitt 4.1.2 und Abschnitt 4.1.3 widmen sich nun der Frage gemäß Schritt 3, mit Hilfe welcher Messsysteme die Messdaten geeignet gesammelt werden können.

Die anschließenden Unterkapitel stellen dann jeweils die Ergebnisse der Punkte 4 bis 6 der Vorgehensweise mit Datengenerierung, Modellschätzung und Modellinterpretation dar. Diskutiert werden ein Teilmodell zur Bestimmung von Fahrzeugbewegungszuständen (Kapitel 4.2), Personenbewegungszuständen (Kapitel 4.3) und des allgemeinen Bewegungsmodus (Kapitel 4.4).

4.1.2 Verwendete Messsysteme

Gemäß der Überlegungen aus Abschnitt 3.2.2 werden für die hier durchgeführten Messungen zwei Arten von Messsystemen genutzt:

- ein Fahrzeug-Referenzsystem in Form der Dresdner Messstraßenbahn sowie
- eine mobile Sensorplattform.

4.1.2.1 Fahrzeug-Referenzsystem: Die Dresdner Messstraßenbahn

Die Dresdner Messstraßenbahn ist ein Kooperationsprojekt zwischen der TU Dresden und mehreren Industriepartnern zur Analyse von Messdaten, die beim Linienbetrieb einer Straßenbahn anfallen. Untersuchungsschwerpunkte sind die Struktur- und Fahrzeugdynamik sowie Energiebetrachtungen und Umwelteinflüsse. Untersuchungsziele dieser Auswertungen sind Verbesserungen der Fahrzeugtechnik, eine Reduktion des Energiebedarfs im Gesamtsystem und eine Beschleunigung des Verkehrsflusses [Harter et al. (2009)].




Abbildung 28: Messstraßenbahn mit Beschleunigungssensorpositionen (1: am Boden des Führerstandes; 2: Drehgestell, nahe Zapfen; 3: unter dem Boden des ersten Portals; 4: Sänfte, mittig unter dem Boden) [Dürschmidt et al. 2012]

In der Messstraßenbahn (siehe Abbildung 28) sind sieben triaxiale, kapazitive MEMS-Beschleunigungssensoren des Typs KISTLER K-Beam Type 8393B10 (siehe Abbildung 29) verbaut, von denen vier dazu verwendet werden können, um Bewegungen des Wagenkastens zu beobachten. Sensor und Datenverarbeitungssystem wurden so entworfen, dass sie den Anforderungen aus Unterkapitel 2.3 zur Beschleunigungsmessung genügen. Detaillierte Angaben zu Systemparametern finden sich in Anhang C.



Abbildung 29: Ein in der Messstraßenbahn verbauter Beschleunigungssensor vom Typ KISTLER K-Beam, Abbildung beschnitten aus [Harter et al. 2009]

Die Rohmessdaten für die nachfolgend beschriebenen und diskutierten Untersuchungen stammen aus dem Archiv der Messstraßenbahn [Dürschmidt 2014].

4.1.2.2 Mobile Sensorplattform

Als mobile Sensorplattform stand für diese Arbeit das Entwicklungsboard „deRFnode“ der Firma Dresden Elektronik zur Verfügung [DE 2016]. Auf dieser Platine ist der Sensor BMA 150 verbaut, ein ebenfalls kapazitiver MEMS-Beschleunigungssensor. Sensor und Datenverarbeitungssystem können so eingestellt werden, dass sie den Anforderungen aus Unterkapitel 2.3 zur Beschleunigungsmessung genügen. Detaillierte Angaben zu Systemparametern finden sich in Anhang C.




Abbildung 30: Sensorplattform: Entwicklungsboard deRFnode von Dresden Elektronik

4.1.2.3 Weitere Systeme

Im Rahmen von Voruntersuchungen zu dieser Arbeit wurden weitere Versuche mit mobilen Referenzsystemen (DEWETRON-basiert [Partzsch et al. 2013 a], NI cRIO-basiert [Partzsch et al. 2013 c]) sowie mit gängigen Smartphones [Partzsch et al. 2012, Partzsch et al. 2013b] durchgeführt. Die Schlussfolgerungen aus diesen Arbeiten flossen in den Entwurf und die Durchführung der vorgenommenen Versuche mit ein.

4.1.3 Durchführung der Messkampagnen

Die in diesem Kapitel beschriebenen Versuche basieren auf drei Messkampagnen, deren Randbedingungen in diesem Abschnitt dokumentiert werden.

4.1.3.1 Messkampagne zu Fahrzeugbewegungszuständen in der Messstraßenbahn

Für die Aufnahme von Bewegungszuständen einer Straßenbahn werden Daten einer Messfahrt am 14.1.2014 in der Linie 8 in Dresden verwendet. Für diese Fahrt liegen die Daten der Messstraßenbahn sowie der von zwei deRFnodes vor (siehe Abbildung 31).

Leitfragen für diesen Datensatz sind:

- Welche Bewegungszustände der Straßenbahn können mit Hilfe welcher Signalmerkmale in den Messstraßenbahndaten festgestellt werden?
- Welche Bewegungszustände können mit einem bezogen auf das Fahrzeug ruhenden deRFnode festgestellt werden?
- Kann ein deRFnode also, wenn er geeignet befestigt ist, ebenfalls als Fahrzeugreferenz verwendet werden?



Abbildung 31: Messfahrten in der Dresdner Messstraßenbahn mit Sensorboards von Dresden Elektronik (aus [FhG IVI 2014])

4.1.3.2 Messkampagne zu Fahrzeugbewegungszuständen in einem Linienbus

Für die Analyse von Bewegungszuständen in einem Bus werden Daten einer Messfahrt am 30.1.2014 verwendet. Für diese Fahrt liegen die Daten von zwei deRFnodes vor.

Anhand dieses Datensatzes ist zu klären, welche Bewegungszustände des Busses mit Hilfe welcher Signalmerkmale in einem bezogen auf das Fahrzeug ruhenden deRFnode festgestellt werden können.

4.1.3.3 Messkampagne zu Personenbewegungszuständen

Zur Aufnahme von Personenbewegungszuständen wurde am 30.1.2015 und 28.4.2015 von zwei verschiedenen Testpersonen folgender Bipediezyklus mit Hilfe des deRFnodes in der Fahrzeughalle des Technikums am Fraunhofer IVI aufgenommen:

- Ruhe → Treppe hinuntergehen → laufen in der Ebene → gehen in der Ebene → Ruhe → 180° Wende
- Ruhe → gehen in der Ebene → laufen in der Ebene → Treppe hinaufgehen → Ruhe → 180° Wende
- Ruhe → Treppe hinuntergehen → gehen in der Ebene → laufen in der Ebene → Ruhe → 180° Wende
- Ruhe → laufen in der Ebene → gehen in der Ebene → Treppe hinaufgehen → Ruhe → 180° Wende
- Ruhe → Treppe hinunterlaufen → laufen in der Ebene → Ruhe → 180° Wende
- Ruhe → laufen in der Ebene → Treppe hinauf laufen → Ruhe → 180° Wende
- Ruhe → Treppe hinunterlaufen → gehen in der Ebene → Ruhe → 180° Wende
- Ruhe → gehen in der Ebene → Treppe hinauflaufen → Ruhe → 180° Wende

Die Plattform wurde an der Kleidung körpernah fixiert.

Leitfragen für diese Datensätze sind:

- Welche Personenbewegungszustände können mit Hilfe welcher Signalmerkmale festgestellt werden?
- Sind die Personenbewegungszustände unabhängig von der Testperson feststellbar?

4.1.3.4 Zusammensetzte Messkampagne für die Untersuchung zum Bewegungsmodus

Aus den oben genannten Messreihen wurde eine synthetische Messreihe zum Unterscheiden der Bewegungsmodi mit der Abfolge Laufen → Busfahrt inkl. Halt-Laufen-Straßenbahnfahrt inkl. Halt- Laufen generiert. Anhand dieses Datensatzes soll die Trennbarkeit der Bewegungsmodi untersucht werden.

Als komplexes Testszenario wurde am 8.6.2015 von einer Testperson im Netz der Dresdner Verkehrsbetriebe mehrere Bewegungsmodi kombinierende Messreihe mit Hilfe des deRFnodes aufgenommen:

- Gehen von Haltestelle Wasaplatz zu Fahrzeug der Linie 9,

- Fahrt mit Straßenbahn zur Haltestelle Gret-Palucca-Str.,
- Umstieg inkl. Haltesteigwechsel in Bus Linie 66,
- Fahrt mit Bus zur Haltestelle Caspar-David-Friedrich-Str.,
- Gehen zur Haltestelle Zellescher Weg.

Die Plattform wurde wiederum an der Kleidung körpernah fixiert.

Leitfrage für diesen Datensatz ist, ob diese am Körper einer Testperson aufgenommenen Signale geeignet sind, Bewegungsmodi (Bus, Bahn, Personenbewegung) abzubilden und ob die Fahrzeugbewegungen detailliert unterschieden werden können.

4.2 Versuch 1: Schätzung des Bewegungszustandes eines Fahrzeugs

Dieses Unterkapitel befasst sich mit der Bewegungszustandsschätzung von Fahrzeugen, inklusive des Merkmalsvergleiches für Messwertreihen zweier in einem Fahrzeug befindlicher Messsysteme.

4.2.1 Erwartete Charakteristika der Fahrzeugbewegungszustände

Es soll nun für jeden Fahrzeugbewegungszustand diskutiert werden, in wie weit sich statistische und spektrale Parameter (siehe Abschnitt 2.6.3) gegenüber einem im Stand aufgenommenen Signal verändern. Ausgangspunkt ist ein kalibriertes Signal, welches im Fahrzeugschwerpunkt ausgerichtet am Fahrzeugkoordinatensystem aufgenommen wird. Zur Abschätzung der Signaländerung werden die qualitativen Erkenntnisse aus Abschnitt 2.2.3 zu markanten Fahrzeugschwingungsphänomenen angewendet. Die Analyse beschränkt sich auf das Signal der Achse, in der die größte Auswirkung auf Grund des jeweiligen Phänomens zu erwarten ist. Prinzipiell ist davon auszugehen, dass in jedem der drei Signale eine Änderung durch einen geänderten Fahrzeugbewegungszustand eintritt.

In den Abschnitt 4.2.2 bis Abschnitt 4.2.5 wird diskutiert, mit welchem konkreten Signalmerkmal sich ein Fahrzeugbewegungszustand in einer Achse von den jeweils anderen Zuständen der gleichen Achse unterscheidet. Dies erfolgt zunächst mittels Messstraßenbahndaten. Anschließend wird überprüft, ob diese Merkmale für Signale der deRFnodes gelten. Der letzte Abschnitt befasst sich mit den Fahrzeugbewegungszuständen eines Busses.

Tabelle 2: Erwartete Signalcharakteristika der verwendeten Fahrzeugbewegungszustände in den drei Signalachsen im Fahrzeugkoordinatensystem unabhängig vom Fahrzeugtyp

Fahrzeugbewegungszustand	Lageparameter	Streuungsparameter	Spektrale Parameter
Stand	x, y, z zentriert um 0	Streuung für x, y, z minimal (Sensorrauschen, ggf. Motorvibration)	minimale Amplituden unabhängig von der Frequenz, ggf. Motorvibration ab 6 Hz
Positiv Beschleunigen	$x > 0$	Erhöhte Streuung gegenüber Stand unabhängig vom Fahrzeugzustand, keine detaillierte Unterscheidbarkeit der Fahrzeugzustände auf Basis der Streuungsparameter	Erhöhte Amplituden in x im Bereich 0..15 Hz gegenüber Stand unabhängig vom Fahrzeugzustand, keine detaillierte Unterscheidbarkeit der Fahrzeugzustände auf Basis der spektralen Parameter
Beharren	x zentriert		
Negativ Beschleunigen	$x < 0$		
Haltevorgang	x zentriert		
Geradenfahrt	y zentriert	Streuung für y erhöht gegenüber Stand	Amplitudenerhöhung für y im Bereich 0-20 Hz gegenüber Stand
Linkskurve	$y < 0$	Erhöhte Streuung gegenüber Geradenfahrt unabhängig von der Kurvenrichtung, keine Richtungsunterscheidung	Erhöhte Amplituden für y im Bereich 0-20 Hz gegenüber Geradenfahrt unabhängig von der Kurvenrichtung, keine Richtungsunterscheidung
Rechtskurve	$y > 0$		
Glatter Untergrund	z zentriert, keine Unterscheidung auf Basis eines Lageparameters	Streuung für z erhöht gegenüber Stand	Amplituden für z erhöht im Bereich 0-30 Hz gegenüber Stand
Holpriger Untergrund		Streuung für x, y und z erhöht gegenüber Fahrt auf glattem Untergrund	Erhöhte Amplituden für x, y und z im Bereich 0-30 Hz gegenüber Fahrt auf glattem Untergrund
Ebenenfahrt	z zentriert	Erhöhte Streuung für z gegenüber Stand unabhängig von der Neigung, keine Neigungsunterscheidung auf Basis der Streuungsparameter	Amplitudenerhöhung für z im Bereich 0-30 Hz gegenüber Stand
Bergfahrt	$z > 0$		Amplitudenerhöhung für z im Bereich 0-30 Hz gegenüber Stand unabhängig von der Neigung, keine Neigungsunterscheidung
Talfahrt	$z < 0$		

4.2.2 Signalanalyse der Messstraßenbahndaten

Im Sinne einer bestmöglichen Fahrzeugreferenz werden zunächst die Messstraßenbahndaten der in Abschnitt 4.1.3 beschriebenen Messkampagne analysiert. Dazu wurden die Merkmale aus Abschnitt 3.4.3 für jeweils eine Sekunde lange Signalausschnitte für die drei Signalachsen berechnet (Boxplots siehe Anhang D). Der Signalausschnitt wurde so gewählt, dass bei den beschriebenen Bewegungen trotz der Bewegung von quasistatischen Signalen ausgegangen werden können, um

sinnvolle statistische Aussagen über diese Abschnitte treffen zu können. Vorversuche stützen diese These. Die oben dargestellten erwarteten Signalcharakteristika der Bewegungszustände konnten bestätigt werden.

Anschließend wurde die Korrelationsmatrix für jede der drei Achsen berechnet. Diese zeigt die linearen Abhängigkeiten zwischen den Merkmalen (Indizes siehe Abschnitt 3.4.3), wie in Abbildung 32 dargestellt.




Abbildung 32: Korrelationsmatrizen für Messstraßenbahnsignale

Unabhängig von der Signalachse lassen sich drei Merkmalsgruppen identifizieren, deren Mitglieder bezogen sich auf eine Signalachse ähneln:

- eine Merkmalsgruppe, deren Mitglieder mit dem Mittelwert des Signals in Zusammenhang stehen
- eine Merkmalsgruppe, deren Mitglieder mit der Streuung des Signals im Zusammenhang stehen (dies sind teilweise spektrale Parameter)
- eine Merkmalsgruppe, deren Mitglieder mit keinem weiteren Merkmal außer mit sich eine hohe Korrelation aufweist.

Die Merkmale können mit Hilfe der Korrelationskoeffizienten-Matrix wie folgt reduziert werden:

- x -Achse: Mittelwert (oder anderes mittelwertabhängiges Merkmal), Spannweite (oder anderes streuungsabhängiges Merkmal), Variationskoeffizient, Schiefe, Signalenergie, Nulldurchgänge
- y -Achse: Mittelwert (oder anderes mittelwertabhängiges Merkmal), Modalwert (oder anderes streuungsabhängiges Merkmal), Variationskoeffizient, Schiefe
- z -Achse: Mittelwert (oder anderes mittelwertabhängiges Merkmal), Modalwert oder anderes streuungsabhängiges Merkmal, Variationskoeffizient, Nulldurchgänge (oder Frequenz mit maximaler Amplitude)

Diese Erkenntnisse zu unabhängigen Merkmalsgruppen und Merkmalen sind Ausgangspunkt für die Entwicklung eines empirischen Entscheidungsbaums mit Hilfe von geeigneten Schwellwerten.

In Abbildung 33 sind exemplarisch für die drei Signalachsen jeweils drei Merkmale mit Hilfe von Boxplots dargestellt. Die Zuordnung der Intervalle zu den Fahrzeugbewegungen erfolgte auf Basis der Messfahrtprotokolle. Diese Darstellungsform gibt Aufschluss über die Trennbarkeit von Bewegungszuständen mit Hilfe des jeweiligen Merkmals.

Auf Grund der Messwertverteilung erscheint es zweckmäßig, den Zustand „Stand“ von allen anderen Zuständen der x -Achse mit Hilfe der Varianz zu trennen. „Beschleunigung“, „Beharren“ und „Bremsen“ sind potentiell über den Mittelwert unterscheidbar.

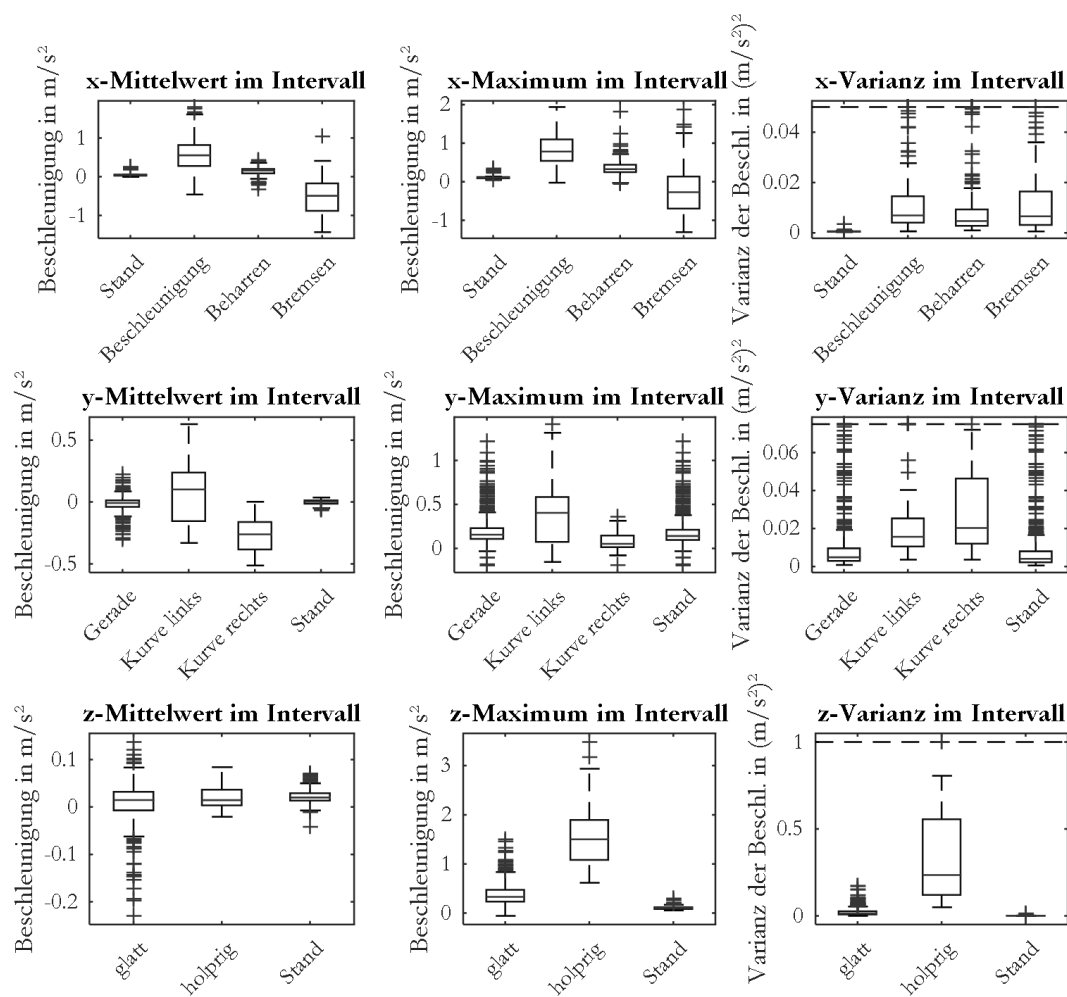


Abbildung 33: Boxplots für Mittelwert, Maximum und Varianz je Intervall für alle drei Achsen der Messstraßenbahnsignale

Für die y -Achse fällt auf, dass der Stand auf Basis dieser drei statistischen Kenngrößen nicht von einer Geradenfahrt unterschieden werden kann. Kurven sind über den Mittelwert unterscheidbar.

In der z -Achse ist eine Trennung von „Stand“ und einer Fahrt auf glattem Untergrund über die Varianz möglich. „Holprige“ Fahrten lassen sich von Fahrten auf glattem Untergrund ebenfalls über die Varianz oder über das Maximum unterscheiden.

Neben den Abhängigkeiten zwischen Merkmalen einer Signalachse kann betrachtet werden, welche Abhängigkeiten es für ein Merkmal für alle drei Signalachsen gibt. Sind solche Korrelationen identifizierbar, könnten diese Erkenntnisse Aufschluss über die Austauschbarkeit der Signalachsen geben. Diese Information kann man für die Reproduktion im Labor nutzen, wenn statt der Anregungsachsen in der Fahrzeugumgebung nur eine Anregungsachse zur Verfügung steht.

In Abbildung 34 sind die linearen Abhängigkeiten zwischen den drei Achsen für alle betrachteten Merkmale in Form der absoluten Korrelationskoeffizienten dargestellt.

Es ergeben sich folgende Erkenntnisse bei der Analyse:

- Für jede Achsenkombination erreichen die Merkmale „absolute Differenz zwischen erstem und letztem Wert im Intervall“ (in der Abbildung Differenz A-E), mittlere Prominenz, FFT-Koeffizientensumme und Spannweite in dieser Reihenfolge die höchsten Korrelationskoeffizienten.
- Dies sind streuungsabhängige Merkmale. Tritt also in einer Achse eine Vibration ein, die eine Erhöhung der Streuung bewirkt, wird diese auf eine andere Achse übertragen.
- Die höchsten Korrelationen ergeben sich zwischen y - und z -Achse. Die Korrelationen zwischen x - und y -Achse sowie zwischen x - und z -Achse sind niedriger. Die Abhängigkeiten der Beschleunigungen in Fahrtrichtung zu denen in Quer- und Hochrichtung sind also geringer als die der Querbeschleunigung zu denen in Hochrichtung.




Abbildung 34: Absolute Korrelationskoeffizienten zwischen den Merkmalen der drei Achsen für Messstraßenbahndaten

4.2.3 Signalanalyse der Straßenbahn-deRFnode-Daten

Vergleichend zu den Analyseergebnissen der Messstraßenbahndaten wird das gleiche Prozedere für die Straßenbahn-deRFnode-Daten der gleichen Fahrt angewandt.

Gleichfalls wurden dazu die Merkmale aus Abschnitt 3.4.3 für jeweils eine Sekunde lange Signalausschnitte für die drei Signalachsen berechnet (Boxplots siehe Anhang E). So wird erreicht, dass bei den beschriebenen Bewegungen trotz der Bewegung von quasistatischen Signalen ausgegangen werden können, um sinnvolle statistische Aussagen über diese Abschnitte treffen zu können. Da die Achsen der Sensorplattform waren parallel zu dem Koordinatensystem der Messstraßenbahn ausgerichtet. Es wird daher erwartet, dass die Signale der gleichen Achsen gleiche Informationen tragen. Die oben dargestellten erwarteten Signalcharakteristika der Bewegungszustände konnten bestätigt werden.

Anschließend wurden die Korrelationsmatrizen der drei Achsen berechnet. Diese zeigt die linearen Abhängigkeiten zwischen den Merkmalen (Indizes siehe Abschnitt 3.4.3), wie in Abbildung 35 dargestellt.




Abbildung 35: Korrelationsmatrizen für Straßenbahn-deRFnode-Daten

Vergleicht man die Korrelationsmatrizen der Straßenbahn-deRFnode-Daten (Abbildung 35) mit denen der Messstraßenbahndaten (Abbildung 32) ergibt sich ein ähnliches Bild mit korrelierten Merkmalsgruppen und unabhängigen Merkmalen. Ein Unterschied in den x -Merkmalen ist die hohe Korrelation der Signalenergie (Merkmal 12) mit den mittelwertkorrelierten Merkmalen 1-3 und 5-6. Für die y - und z -Merkmale fällt auf, dass die negative Korrelation des Modalwerts (Merkmal 3) mit den streuungsabhängigen Merkmalen entfällt.

In Abbildung 36 sind exemplarisch für die drei Signalachsen jeweils die drei Merkmale Mittelwert, Maximum und Varianz mit Hilfe von Boxplots dargestellt. Die Intervallzuordnung zu den Fahrzeugbewegungsklassen erfolgte auf Basis der Messfahrtprotokolle. Aussagen über die potentielle Trennbarkeit von Bewegungszuständen mit Hilfe des jeweiligen Merkmals können in gleichem Umfang wie auf Basis der Messstraßenbahn getroffen werden:

- Trennung des Zustandes „Stand“ von allen anderen Zuständen der x -Achse mit Hilfe der Varianz,
- Unterscheidung von „Beschleunigung“, „Beharren“ und „Bremsen“ über den x -Mittelwert,
- Unterscheidung von Kurvenrichtung durch den Mittelwert des y -Signals,
- Trennung von „Stand“ und einer Fahrt auf glattem Untergrund über die z -Varianz
- Trennung von „Holprige“ Fahrten und Fahrten auf glattem Untergrund ebenfalls über die Varianz.

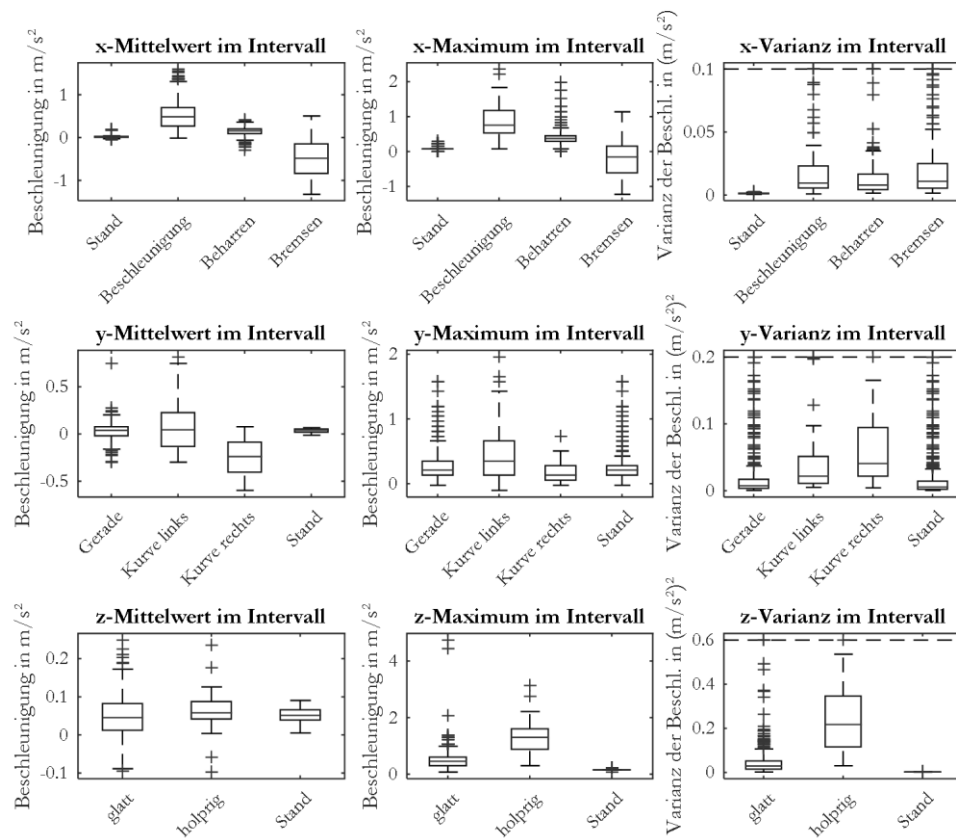


Abbildung 36: Boxplots für Mittelwert, Maximum und Varianz je Intervall für alle drei Achsen der Straßenbahn-deRFnode-Signale

In Abbildung 37 sind die linearen Abhängigkeiten zwischen den drei Achsen für alle betrachteten Merkmale in Form der absoluten Korrelationskoeffizienten dargestellt.

Verglichen mit den Korrelationskoeffizienten für die Messstraßenbahndaten sind hier höhere Werte zu verzeichnen. Dies ist messsystembedingt, da die Befestigung mit dem Fahrzeug nicht über komplette Verklebung realisiert war und somit eine Bewegung des Sensors gegenüber dem Fahrzeug möglich war.




Abbildung 37: Absolute Korrelationskoeffizienten zwischen den Merkmalen der drei Achsen für Straßenbahn-deRFnode-Daten

Für jede Achsenkombination erreichen die Merkmale „absolute Differenz zwischen erstem und letztem Wert im Intervall“ (in der Abbildung Differenz A-E), mittlere Prominenz, FFT-Koeffizientensumme und Spannweite in dieser Reihenfolge die höchsten Korrelationskoeffizienten. Diese Merkmale liefern auch für die Messstraßenbahndaten die höchsten Korrelationen (siehe Abschnitt 4.2.2).

4.2.4 Vergleich der Messstraßenbahndaten mit deRFnode-Daten

Zur Betrachtung der Ähnlichkeit von Messstraßenbahndaten und den parallel aufgezeichneten deRFnode-Daten soll die Korrelation der Merkmale jeweils für die drei Signalachsen betrachtet werden (siehe Abbildung 38).




Abbildung 38: Matrix der absoluten Korrelationskoeffizienten zwischen Merkmalen generiert aus Messstraßenbahndaten und deRFnode-Daten

Unter Verwendung der in Abschnitt 2.5.4 diskutierten Schranken zur Bewertung von Korrelationskoeffizienten, ergibt sich für die beiden betrachteten Datensätze und deren Korrelationskoeffizienten, dass von den jeweils 19 Merkmalen

- in der x -Achse 6 Merkmale eine sehr hohe und 6 Merkmale eine mittlere Korrelation,
- in der y -Achse 8 Merkmale eine hohe und 5 Merkmale eine mittlere Korrelation,

- in der z -Achse 5 Merkmale eine hohe und 3 Merkmale eine mittlere Korrelation

aufweisen.

Bei geeigneter Merkmalsauswahl ist also davon auszugehen, dass eine Sensorplattform in der Lage ist, vergleichbare Signale und damit vergleichbare Merkmale zu produzieren. Durch die gewählte Koppelung mit dem Fahrzeug ist die Korrelation für die x -Achse am höchsten, für die z -Achse am schwächsten.

Es fällt auf, dass die spektralen Merkmale (FFT-Koeffizientensumme, Wavelet-Koeffizientensumme) niedrig korreliert sind. Der Einfluss einer frequenzabhängigen Übertragungsfunktion ist hier zu vermuten.

Zur Bestätigung dieser Vermutung wurde eine empirische, geglättete Übertragungsfunktion durch Division der FFT-Frequenzspektren für einen geraden, glatten Fahrabschnitt von 28 Sekunden Länge für alle drei Signalachsen erzeugt, wie in Abbildung 39 dargestellt. Zur Darstellung wurden die Übertragungsfunktionen geglättet. Für die benötigte Glättungsqualität genügt ein Butterworth-Filter 2. Ordnung bei einer Grenzfrequenz von 0.025 Hz.




Abbildung 39: Übertragungsfunktionen zwischen Messstraßenbahnsignal (Bahn) und Straßenbahn-deRFnode-Signal (deRFnode)

Es ist jeweils der Übertragungsfaktor 1 gekennzeichnet. Liegt die Funktion unter dieser Linie werden die Frequenzen im deRFnode-Signal gegenüber dem Messstraßenbahnsignal gedämpft, liegen die Werte über der Linie, werden die Leistungsanteile gegenüber der Messstraßenbahn verstärkt wiedergegeben. In allen drei Achsen existiert eine systematische Verstärkung im Bereich bis 2 Hz, um 22 Hz und über 42 Hz.

4.2.5 Signalanalyse der Bus-deRFnode-Daten

Analog zu den Messstraßenbahn- und Straßenbahn-deRFnode-Daten wurden für die deRFnode-Daten der im Abschnitt 4.1.3 beschriebenen Busfahrt die Merkmale aus Abschnitt 3.4.3 für jeweils eine Sekunde lange Signalausschnitte für die drei Signalachsen berechnet (Boxplots siehe Anhang F). Wie für die Straßenbahndaten wird erreicht, dass bei den beschriebenen Bewegungen trotz der Bewegung von quasistatischen Signalen ausgegangen werden können, um sinnvolle statistische Aussagen über diese Abschnitte treffen zu können. Die oben dargestellten erwarteten Signalcharakteristika konnten ebenfalls für diese Busfahrt der Bewegungszustände bestätigt werden.

Anschließend wurden die Korrelationsmatrizen der drei Achsen berechnet. Diese zeigt die linearen Abhängigkeiten zwischen den Merkmalen (Indizes siehe Abschnitt 3.4.3), wie in Abbildung 40 dargestellt.




Abbildung 40: Korrelationsmatrizen für Bus-deRFnode-Daten

Vergleicht man die Korrelationsmatrizen für Bus-deRFnode-Daten (Abbildung 40) und Straßenbahn-deRFnode-Daten (Abbildung 35) ergibt sich eine grundsätzlich ähnliche Struktur. Für die x -Merkmale stellt die negative Korrelation der Signalenergie (Merkmal 12; für den Fall der Straßenbahn-deRFnode-Daten positiv) den größten Unterschied dar. Die y -Merkmale weisen eine ähnliche Struktur auf, unterscheiden sich in den Zahlenwerten. Für die z -Merkmale fallen die insgesamt geringere Korrelation der Schiefe (Merkmal 11) mit allen anderen Merkmalen sowie die positive Korrelation der Signalenergie (Merkmal 12) mit den mittelwertkorrelierten Merkmalen auf.

In Abbildung 41 sind exemplarisch für die drei Signalachsen jeweils die drei Merkmale Mittelwert, Maximum und Varianz mit Hilfe von Boxplots dargestellt. Die Intervalle wurden auf Basis der Messfahrtprotokolle klassifiziert.

Aussagen über die potentielle Trennbarkeit von Bewegungszuständen mit Hilfe des jeweiligen Merkmals können in gleichem Umfang wie auf Basis der Messstraßenbahn oder der Straßenbahn-deRFnode-daten getroffen werden:

- Trennung des Zustandes „Stand“ von allen anderen Zuständen der x -Achse mit Hilfe der Varianz,
- Unterscheidung von „Beschleunigung“, „Beharren“ und „Bremsen“ über den x -Mittelwert,
- Unterscheidung von Kurvenrichtung durch den Mittelwert des y -Signals,
- Trennung von „Stand“ und einer Fahrt auf glattem Untergrund über die Varianz
- Trennung von „Holprige“ Fahrten und Fahrten auf glattem Untergrund ebenfalls über die Varianz.

Es sollte also möglich sein, eine vom Fahrzeugtyp unabhängige Klassifikatorstruktur zur Bestimmung des Fahrzeugbewegungszustandes zu erstellen.

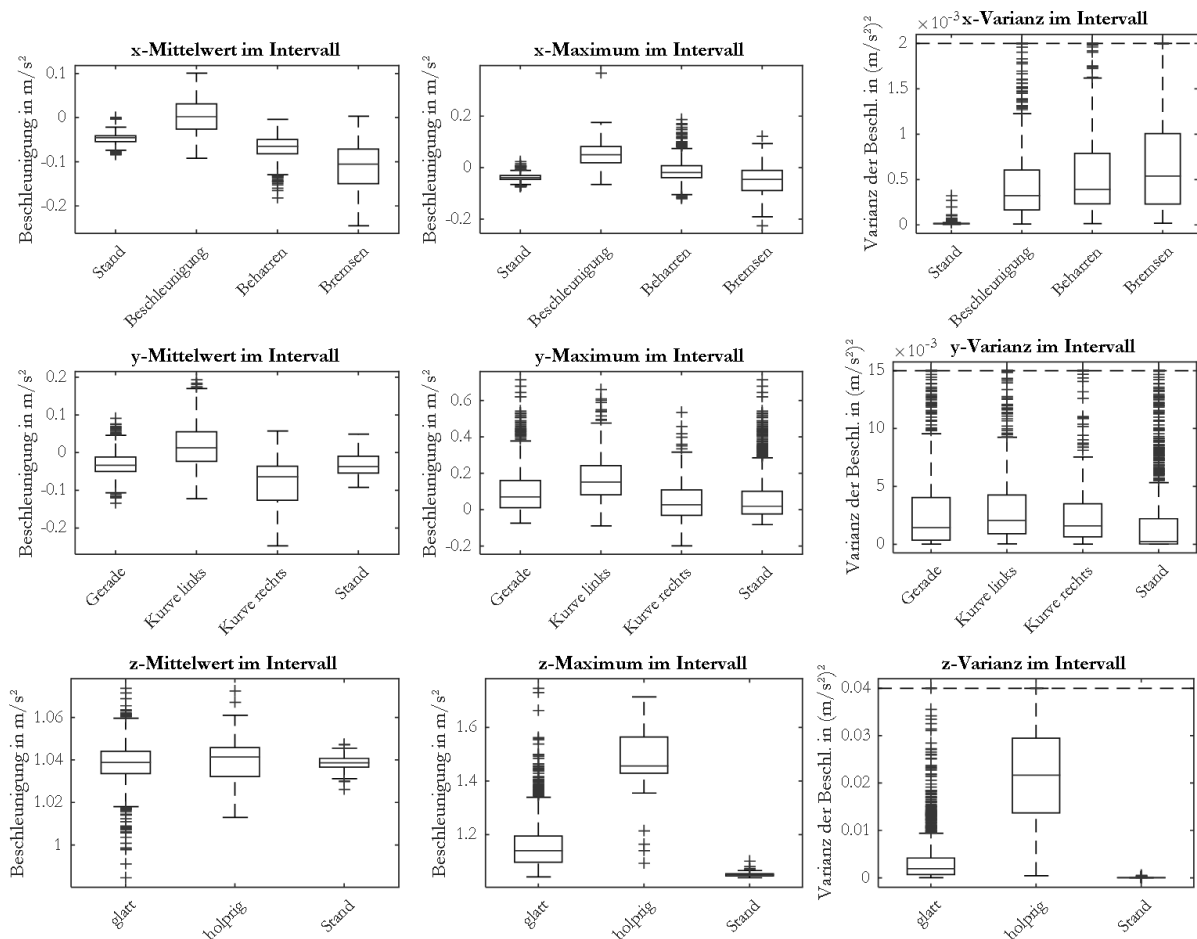


Abbildung 41: Boxplots zu Mittelwert, Maximum und Varianz der Bus-deRFnode-Daten

In Abbildung 42 sind die linearen Abhängigkeiten zwischen den drei Achsen für alle betrachteten Merkmale in Form der absoluten Korrelationskoeffizienten dargestellt.




Abbildung 42: Absolute Korrelationskoeffizienten zwischen den Merkmalen der drei Achsen für Bus-deRFnode-Daten

Vergleicht man die Absoluten Korrelationskoeffizienten der Bus-deRFnode-Daten (Abbildung 42) mit den Straßenbahn-deRFnode-Daten (Abbildung 37) ergibt sich eine ähnliche Struktur. Sie weist noch höhere Korrelationen für die für die Straßenbahndaten hoch korrelierten Merkmale, wie Differenz von Anfang- und Endwert eines Intervalls, Summe der FFT-Koeffizienten, Prominenz, Spannweite, Standardabweichung auf.

4.2.6 Ableitung des heuristischen Entscheidungsbaums

Die Signalanalyse in den vorangegangenen vier Unterabschnitten hat gezeigt, dass unabhängig vom Fahrzeugtyp und der Art der Datenaufnahme aussagekräftige Merkmale für die Unterscheidung von Fahrzeugbewegungszuständen gefunden werden können.

In diesem Abschnitt wird dazu ein allgemeiner vom Fahrzeugtyp unabhängiger Entscheidungsbaum-Klassifikator für Fahrzeugbewegungen entwickelt.

4.2.6.1 Globale Ablauflogik

Die Grundlage bildet eine globale Ablauflogik (siehe Abbildung 43), die bei der Feststellung geeigneter Zustände (Halt, Geradenfahrt) eine Mittelwertkalibrierung des Signals vornimmt und so eine Klassifikation auf Basis von Mittelwerten ermöglicht. Diese Kalibrierung ist zur Nachführung des Sensorsignals notwendig, wenn äußere Einflüsse (Koordinatensystemverschiebungen, Temperatureinflüsse) den Mittelwert des Sensorsignals beeinflusst haben.

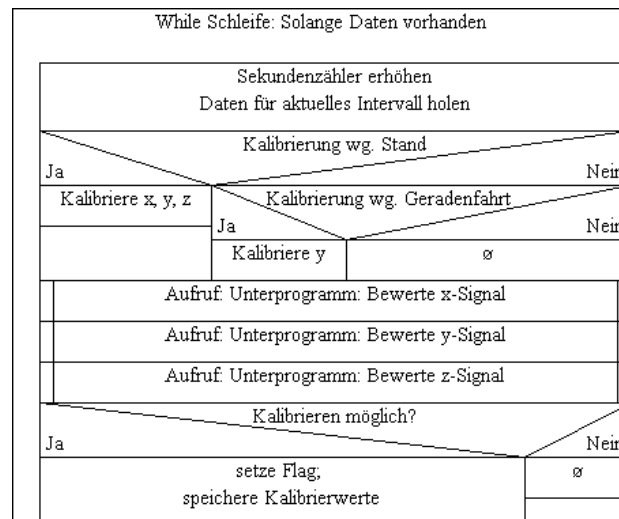


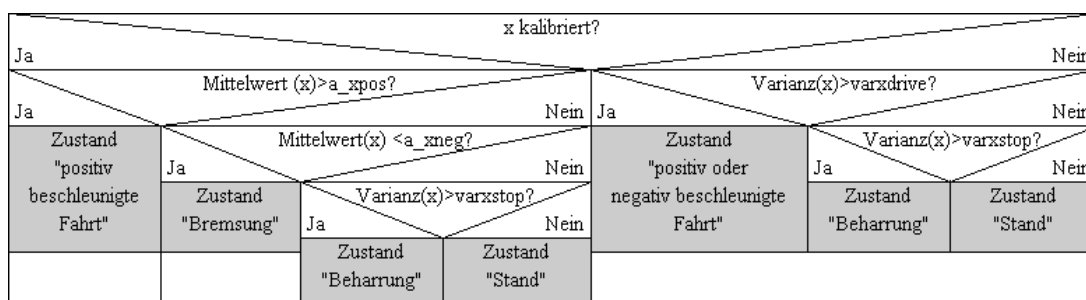
Abbildung 43: Struktogramm der globalen Klassifikatorlogik (ø - keine Aktion)

4.2.6.2 Detaillogik Bewertung des x -Signals

Ausgehend von der Signalanalyse der vorangegangenen Abschnitte wird folgender Entscheidungsmechanismus (siehe Abbildung 44) vorgeschlagen:

- Entscheidung zwischen Stand und jedem anderen Fahrtzustand über die Varianz (Schwellwerte $varx_{stop}$ für Stand und $varx_{drive}$ für Fahrt),
- Entscheidung zwischen positiv, negativ oder nicht beschleunigter Fahrt über den Mittelwert (Schwellwerte a_{xpos} für positive Beschleunigung und a_{xneg} für negative Beschleunigung).

Da die mittelwertbasierte Entscheidung nur für kalibrierte Signale sinnvoll ist, wird in diesem Fall auf Basis der Varianz zwischen Stand, Beharrung und beschleunigten Zuständen unterschieden.

Abbildung 44: Struktogramm der x -Signal-Klassifikatorlogik4.2.6.3 Detaillogik Bewertung des y -Signals

Die Bewertung des y -Signals (siehe Abbildung 45) ist lediglich bei einem kalibrierten Signal sinnvoll, da dann auf Basis des Mittelwertes (Schwellwerte a_{ypos} für Rechtskurve und a_{yneg} für Linkskurve)

die Kurvenrichtung unterschieden werden kann. Im Gegensatz zum x -Signal ist eine Trennung von einem allgemeinen „Kurvenfahrt“-Zustand von der Geradenfahrt mit Hilfe der Varianz nicht möglich.

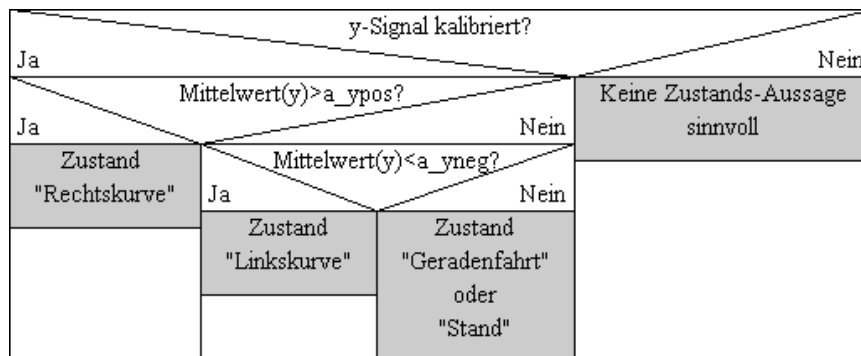


Abbildung 45: Struktogramm der y -Signal-Klassifikatorlogik

4.2.6.4 Detaillogik: Bewertung des z -Signals

Im Gegensatz zur Bewertung des x - und y -Signals ist die Bewertung des z -Signals (siehe Abbildung 46) ohne vorherige Signalkalibrierung möglich, da die Bewertung auf der Varianz des Signals beruht (Schwellwerte $varz_{flat}$ für Holprigkeit und $varz_{stop}$ für Stand).

Eine Kalibrierung der Signalvarianz ist denkbar, wurde hier nicht verwendet.




Abbildung 46: Struktogramm der z -Signal-Klassifikatorlogik

4.2.7 Diskussion der Transmissions- und Emissionsmatrix zur HMM-Filterung

Auf Basis der Straßenbahn-deRFnode-Daten wurden Transmissions- und Emissionsmatrix generiert. Abbildung 47 enthält die deren Zahlenwerte.

Es fällt auf, dass anhand der vorliegenden Daten weitere Zustandsübergänge (Transmissionen) existieren, die in den Vorüberlegungen (Abbildung 21) nicht enthalten waren.

Weiterhin ist es für den vorliegenden Datensatz ein sicheres Ereignis, dass, wenn eine negative Beschleunigung als Klassifikatorlösung vorliegt, tatsächlich eine negative Beschleunigung zu beobachten war.

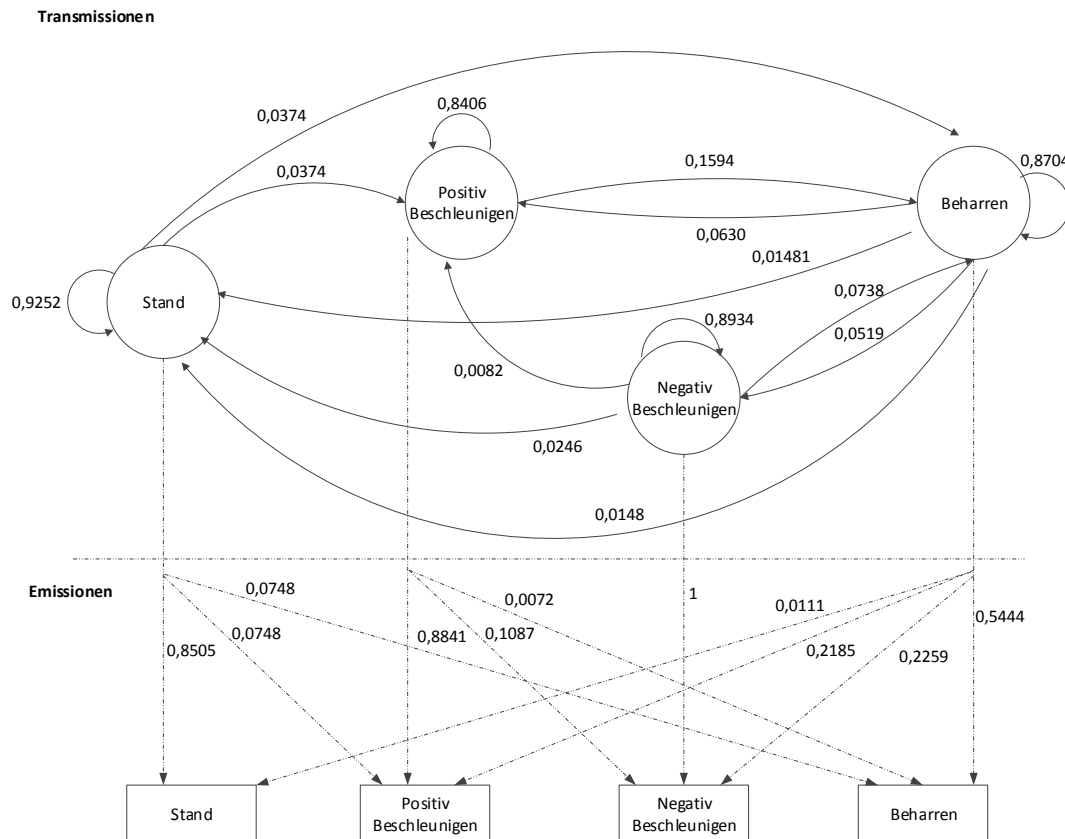


Abbildung 47: Visualisierung der Transmissions- und Emissionsmatrix für Straßenbahn-deRFnode-Daten

4.2.8 Ermittlung des Trainingsfehlers

Zur Bestimmung des Trainingsfehlers bei der Klassifikation von Fahrzeugbewegungen wurden für jede Signalachse aller Datensätze (Messstraßenbahndaten, Straßenbahn-deRFnode-Daten, Bus-deRFnode-Daten) für alle drei bisher besprochenen Klassifikatortypen (Entscheidungsbaum (in Abbildung „DT“), linearer (in Abbildung „lin“) und quadratischer Diskriminanzanalyse-Klassifikator (in Abbildung „qud“) ein Klassifikator und ein HMM-Filter (in Abbildung „+HM“) erstellt. Diese für das Training der Klassifikatoren und Filter verwendeten Daten wurden anschließend zum Test verwendet und geben somit Aufschluss über eine obere Schranke der erreichbaren Klassifikationsgüte mit der jeweiligen Verfahrensweise (Klassifikatortyp mit oder ohne nachgeschaltetem HMM-Filter).

Die Korrektheit als Anteil der richtigen Entscheidungen an allen getroffenen Entscheidungen ist in Abbildung 48 für die betrachteten Klassifikatoren dargestellt. Als Vergleichsmaßstab dienen zwei Wahrscheinlichkeiten für die Korrektheit zweier einfacher Klassifikatorvarianten: die Wahrchein-

lichkeit einer richtigen Entscheidung bei Gleichverteilung aller Zustände, sowie die Wahrscheinlichkeit einer richtigen Entscheidung bei Annahme des Zustandes mit höchster Häufigkeit im jeweiligen Trainingsdatensatz.

Für den Fall, dass die Testdaten diejenigen Daten sind, die zum Training verwendet wurden, erreichen die Klassifikatoren unabhängig von der Signalquelle und damit unabhängig von der Größe der Datengrundlage eine vergleichbare Korrektheit, die in jedem Fall über den geforderten wahrscheinlichkeitsbasierten Güteschranken der naiven Klassifikatoren aus Abschnitt 2.6.6 liegt. Die Korrektheit schwankt je Datensatz und Signalachse im Mittel um 3,8 Prozentpunkte (maximal in der x -Achse für die Messstraßenbahndaten um 8,2 Prozentpunkte minimal für die Straßenbahn-deRFnode-Daten der y -Achse um 0,47 Prozentpunkte).

In der x -Achse ist für die drei Datensätze der quadratische Diskriminanzanalyse-Klassifikator der beste. Für die y -Achse ist für jeden Datensatz ein anderer Klassifikator der beste und in der z -Achse ist der Entscheidungsbaum der beste.

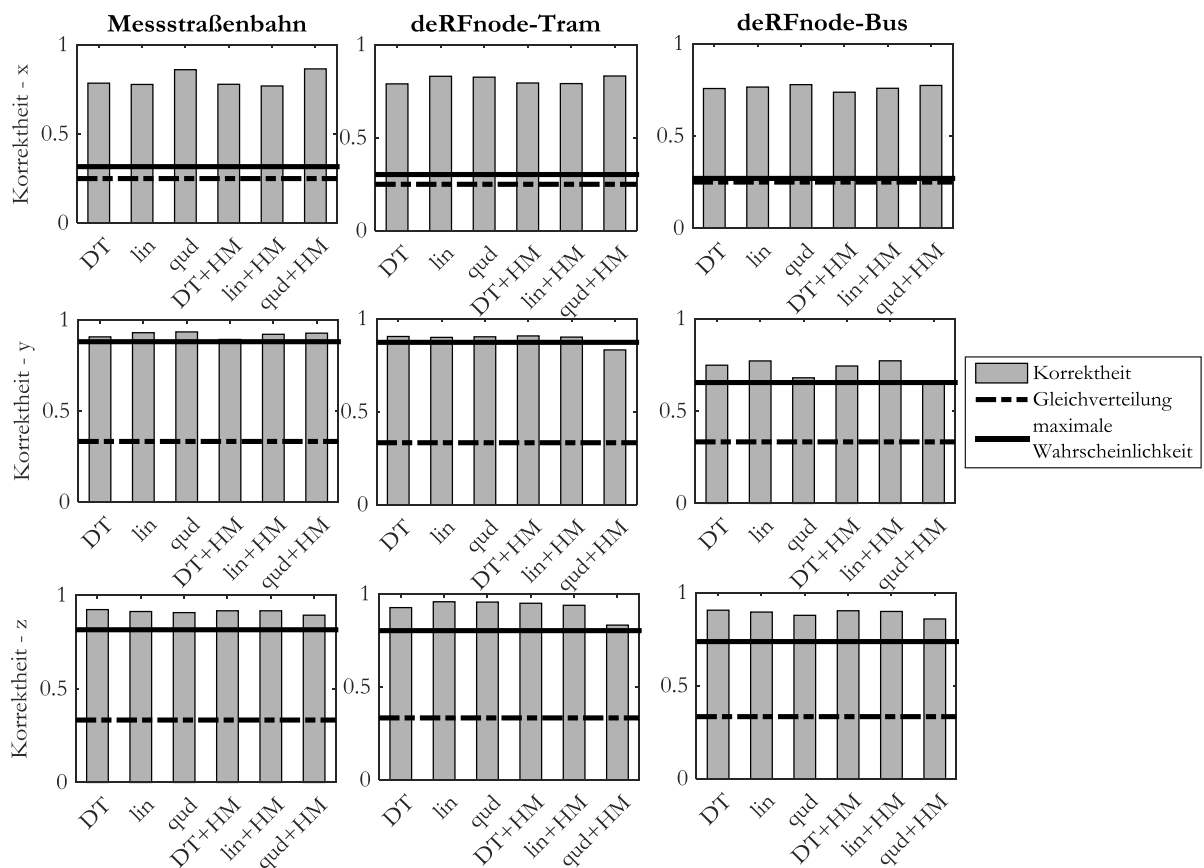


Abbildung 48: Trainingsfehler der Fahrzeugbewegungszustände-Klassifikatorvarianten (Entscheidungsbaum (DT), Diskriminanzanalyse mit linearer (lin) oder quadratischer (qud) Diskriminanzfunktion, ggf. mit HMM-Filterung (HM)) verglichen mit Güteschranken

Für die Wirksamkeit der HMM-Filterung lässt sich die Aussage treffen, dass über alle Klassifikatorvarianten und Datensätze keine deutliche Verbesserung durch automatisch generierten HMM-Filter festzustellen ist. Über alle Varianten nimmt die Korrektheit um 1,3 Prozentpunkte ab. Bis auf zwei quadratische Diskriminanzanalyse-Klassifikatoren für y -Signale von Straßenbahn- und Bus-deRFnode-Daten erfüllen alle Klassifikatoren mit HMM-Filterung die wahrscheinlichkeitsbasierten Güteschranken.

Es sind für ein Drittel aller Klassifikatorvarianten Verbesserungen festzustellen (maximal um bis zu 2,4 Prozentpunkte für den \hat{x} -Achsen-Entscheidungsbaum der Straßenbahn-deRFnode Daten). Die maximale Verschlechterung beträgt 12,4 Prozentpunkte für den quadratischen Diskriminanzanalyse-Klassifikator des \hat{x} -Achsen-Signals ebenfalls für die Straßenbahn-deRFnode Daten.

Für eine detaillierte Bewertung der entstandenen Klassifikatoren kann für jeden der insgesamt 54 Klassifikatorvarianten, die in Abbildung 48 dargestellt sind, die Verwechslungsmatrix gemäß Formel (14) betrachtet werden.

Die in Abschnitt 2.6.6 eingeführte Verwechslungsmatrix

$$\mathbf{V} = \begin{pmatrix} v(0,1) & v(0,2) & \cdots & v(0,K) \\ v(1,1) & v(1,2) & \cdots & v(1,K) \\ \vdots & \vdots & & \vdots \\ v(e,1) & v(e,2) & \cdots & v(e,K) \end{pmatrix}$$

enthält dann die folgenden Werte für die $v(e,k)$ mit dem klassifizierten Zustand e und den tatsächlichen Zustand k für den Entscheidungsbaumklassifikator des Messstraßenbahnsignals in x -Richtung (Ausgegebener Zustand | Wahrer Zustand):

Stand Stand = 89	Stand Beschleunigen = 0	Stand Beharren = 2	Stand Bremsen = 0
Beschleunigen Stand = 2	Beschleunigen Beschleunigen = 123	Beschleunigen Beharren = 64	Beschleunigen Bremsen = 0
Beharren Stand = 0	Beharren Beschleunigen = 8	Beharren Beharren = 151	Beharren Bremsen = 3
Bremsen Stand = 0	Bremsen Beschleunigen = 2	Bremsen Beharren = 56	Bremsen Bremsen = 157

Es lässt sich folgern, dass der Stand von den anderen drei Zuständen zu trennen ist, wohingegen zwischen den drei anderen Zuständen Unschärfen bestehen, die sich in Fehlklassifikationen äußern.

4.2.9 Ermittlung des Generalisierungsfehlers

Zur Bewertung der Generalisierungsfähigkeit der getroffenen Aussagen wurden die in der zusammengesetzten Messkampagne gesammelten Daten verwendet. Hierbei wurde der Straßenbahnabschnitt für den Test der mit den Straßenbahn-deRFnode angelerten Klassifikatoren und der Busabschnitt für den Test der mit den Bus-deRFnode angelerten Klassifikatoren verwendet.

Gegenüber dem Trainingsfehlerversuch ist nun eine Verbesserung der Klassifikation durch die HMM-Filterung festzustellen. Über alle Varianten verbessern sich die Ergebnisse gegenüber der ungefilterten Variante um 4,3 Prozentpunkte. Insgesamt tritt die Verbesserung für 61% der Klassifikatoren ein. Am höchsten ist die Verbesserung für die Entscheidungsbaum-Klassifikatoren. Im Mittel beträgt sie 8,2 Prozentpunkte (maximal 21,5 Prozentpunkte, minimal 0,3 Prozentpunkte).

4.3 Versuch 2: Schätzung des Bewegungszustandes einer Person

Dieses Unterkapitel befasst sich mit der Bewegungszustandsschätzung von Personen.

4.3.1 Theoretische Charakteristika der Personenbewegungszustände

Die im Abschnitt 2.2.4 erläuterten Arbeiten zur Signalanalyse von Bipedie-Signalen zeigen, dass die Frequenzen größter Amplitude durch die Schrittfrequenz beeinflusst sind. Mit Erhöhung der Geschwindigkeit nehmen so Schrittfrequenz und die Frequenz der größten Amplitude. Für das normale (gehende) Treppensteigen fand Bosina (2012) eine gegenüber dem Gehen in der Ebene geringere Schrittfrequenz. Es ist umgekehrt beim Abwärtsgehen zu erwarten, dass die Schrittfrequenz gegenüber der Fortbewegung in der Ebene zunimmt.

Auf Grund der Fokussierung auf die Schrittfrequenz erscheint es zweckmäßig, die Analysen auf das \tilde{x} -Signal zu beschränken, da in dieser Achse der Bodenkontakt den größten Signalanteil hat. In den anderen Signalachsen sind hingegen die Vor-/Zurückbewegung des Oberkörpers (x -Achse) und die Hüftbewegung (y -Achse) maßgebliche Signalbestandteile.

Im \tilde{x} -Signal werden die in der Tabelle 3 zusammengefassten Signalbestandteile erwartet.

Tabelle 3: Theoretische Charakteristika der verwendeten Personenbewegungszustände

Personenbewegungszustand	Lageparameter	Streuungsparameter	Spektrale Parameter
Stand/langsame Bewegung	zentriert um 0	minimal (Sensorrauschen)	minimale Amplituden unabhängig von der Frequenz
Laufen		Höher als beim Gehen	Frequenz größter Amplitude durch erhöhte Schrittfrequenz
Laufen, Treppe auf		Höher als beim Gehen (alle Varianten), aber niedriger als beim Laufen	höher als im Stand und beim Gehen
Laufen, Treppe ab		Höchste Spannweite in \ddot{x} durch Abwärtsbewegung	
Gehen		Höher als im Stand	Frequenz größter Amplitude durch Schrittfrequenz
Gehen, Treppe auf		Höher als im Stand, aber niedriger als Gehen	höher als im Stand
Gehen, Treppe ab		Höher als beim Gehen, aber niedriger als Laufen (alle Varianten)	

4.3.2 Signalanalyse

Analog zu den Fahrzeugdaten wurden für die Bipedie-deRFnode-Daten die im Abschnitt 3.4.3 gelisteten Merkmale für jeweils eine Sekunde lange Signalausschnitte für die drei Signalachsen berechnet. Wie für die Fahrzeugdaten diskutiert, werden durch diese Abschnittsbildung quasistatische Signale erzeugt, für die eine statistische Analyse sinnvoll ist. (Indizes siehe Abschnitt 3.4.3) je Signalachse die Korrelationsmatrizen erstellt werden, wie in Abbildung 50 gezeigt. Diese zeigen im Gegensatz zu den Fahrzeugdaten über alle drei Signalachsen hinweg ähnliche Strukturen.




Abbildung 50: Korrelationsmatrizen für Bipedie-deRFnode-Daten

Gemäß den Ausführungen zu den theoretischen Charakteristika von Personenbewegungszuständen wurde für die Überprüfung, ob eine Trennung der einzelnen Zustände auf Basis des gemessenen Signals möglich ist, die Intervall-Spannweite herangezogen. Boxplots für alle drei Signalachsen sind in Abbildung 51 dargestellt. Vergleicht man die drei Signalachsen, zeigt sich für x und z eine deutliche Trennschärfe der jeweiligen Hauptbereiche der Merkmalswerte. Diese ist für das y -Signal schwächer ausgeprägt.




Abbildung 51: Boxplots für Spannweiten je Intervall für alle drei Achsen der Bipédie-deRFnode-Signale

4.3.2.1 Zusammenhänge zwischen den Signalen der drei Achsen

Wie für die Fahrzeugsignale wurde für die Bipédie-deRFnode-Daten untersucht, inwieweit die Merkmale über die drei Signalachsen hinweg korrelieren (siehe Abbildung 52). Hier ist für die Bipédie-deRFnode-Daten im Gegensatz zu den Fahrzeugdaten eine bis auf Ausnahmen hohe bis sehr hohe Korrelation über alle drei Achsen hinweg festzustellen. Der Zusammenhang ist zwischen x - und z -Achse deutlich ausgeprägt. Die nachfolgenden Untersuchungen beschränken sich daher auf die Klassifikation des z -Signals.




Abbildung 52: Absolute Korrelationskoeffizienten zwischen den Merkmalen der drei Achsen für Bipédie-deRFnode-Daten

4.3.2.2 Ableitung des heuristischen Entscheidungsbaums

Auf Basis der Signalanalyse des vorangegangenen Unterabschnittes kann gezeigt werden, dass mit der Spannweite des \ddot{x} -Signals ein Merkmal zur Klassifizierung von Personenbewegungszuständen gefunden werden kann.

Eingebettet in die zur Klassifikation notwendige Ablauflogik zur Erzeugung des jeweiligen Datenabschnitts für ein aktuelles Intervall wird der in Abbildung 53 dargestellte Entscheidungsbaum verwendet. Er basiert lediglich auf Spannweiten-Schwellwerten (*max_Ruhe* für Ruhe, *max_gehen_auf* für Treppe hinaufgehen, *max_gehen* für Gehen in der Ebene, *max_laufen_auf* für Treppe hinauflaufen und *max_laufen* für Laufen in der Ebene).

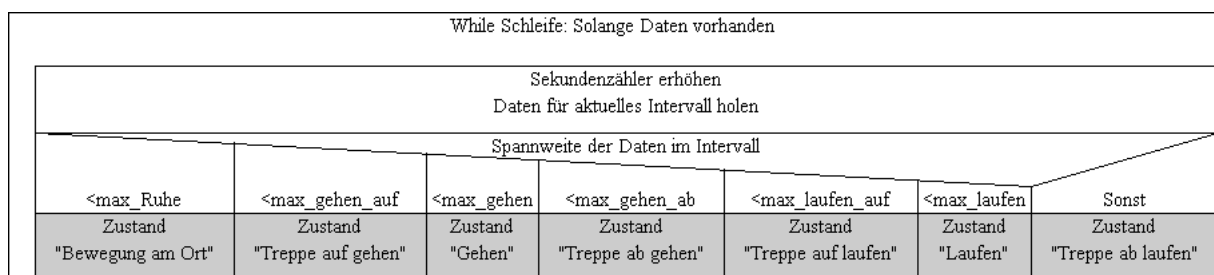


Abbildung 53: Entscheidungsbaum zur Klassifizierung von Personenbewegungen.

4.3.3 Ermittlung des Trainingsfehlers

Wie für die Bewertung der Fahrzeugbewegungsklassifikatoren durchgeführt, wurde der Trainingsfehler bestimmt. Da für die Klassifizierung der Personenbewegung nur eine Signalachse verwendet wurde, wurde für diese für alle drei bisher besprochenen Klassifikatortypen (Entscheidungsbaum (in Abbildung „DT“), linearer (in Abbildung „lin“) und quadratischer Diskriminanzanalyse-Klassifikator (in Abbildung „qud“) ein Klassifikator und ein HMM-Filter (in Abbildung „+HM“) erstellt. Diese für das Training der Klassifikatoren und Filter verwendeten Daten wurden anschließend zum Test verwendet und geben so, wie für die Fahrzeugbewegungsklassifikatoren erläutert, Aufschluss über eine obere Schranke der erreichbaren Klassifikationsgüte für die jeweilige Klassifikatorvariante. In Abbildung 54 ist die Korrektheit als Anteil der richtigen Entscheidungen an allen getroffenen Entscheidungen für die betrachteten Klassifikatoren dargestellt. Als Vergleichsmaßstab dienen die zwei Wahrscheinlichkeiten für die Korrektheit der diskutierten einfachen Klassifikatorvarianten bei Annahme einer Gleichverteilung der Zustände oder Verwendung des Zustandes höchster Häufigkeit im Trainingsdatensatz.

Alle Klassifikatorvarianten ordnen die zu klassifizierenden Intervalle mit einer über den Vergleichsschranken liegenden Korrektheit zu. Auf Grund der Einfachheit der gewählten Entscheidungs-

baumstruktur liegt die Korrektheit dieser Klassifikatorvariante unter denen der Diskriminanz-Analyse-Klassifikatoren – für diesen Typ lieferte die quadratische Diskriminanzfunktion die besten Ergebnisse. Die HMM-Filterung verbesserte lediglich die Entscheidungsbaumklassifikation um 1,9%.




Abbildung 54: Trainingsfehler der Bipedie-Klassifikatorvarianten (Entscheidungsbaum (DT), Diskriminanzanalyse mit linearer (lin) oder quadratischer (qud) Diskriminanzfunktion, ggf. mit HMM-Filterung (HM)) verglichen mit Güteschranken

4.3.4 Ermittlung des Generalisierungsfehlers

Zur Bewertung der Generalisierungsfähigkeit der getroffenen Aussagen wurden die erstellten Klassifikatoren für die Klassifikation eines anderen Datensatzes verwendet. Hierbei lief eine andere Person den gleichen vorgegebenen Bewegungszyklus ab.

Grundsätzlich liegen die Ergebnisse der Klassifikatoren ohne HMM-Filterung über der oberen Güteschranke. Das Ergebnis der Klassifikation mittels linearer Diskriminanzfunktion weist mit 67,6% die höchste Korrektheit auf. Die HMM-Filterung bewirkt eine Verbesserung für das Entscheidungsbauergebnis von 51,4% auf 53,9%. Die Verwendung des Trainings-HMM scheint für die Diskriminanzanalyseklassifikatoren nicht optimal, da die Korrektheit unter dem Ergebnis der Klassifikation ohne Filterung auf der oberen Güteschranke liegt.




Abbildung 55: Generalisierungsfehler der Bipedie-Klassifikatorvarianten (Entscheidungsbaum (DT), Diskriminanzanalyse mit linearer (lin) oder quadratischer (qud) Diskriminanzfunktion, ggf. mit HMM-Filterung (HM)) verglichen mit Güteschranken

4.4 Versuch 3: Schätzung des Bewegungsmodus

Dieses Unterkapitel befasst sich mit der Schätzung des Bewegungsmodus einer im ÖPV mitgeführten Sensorplattform.

4.4.1 Geschichtetes Vorgehen zur Identifikation von Bewegungsmodus und Bewegungszustand

Wie in Abschnitt 3.3.1 diskutiert, wird in dieser Arbeit ein geschichtetes Vorgehen verfolgt, da dieses das Training auf Basis einer kleinen Datengrundlage ermöglicht. Nachfolgend wird daher separat diskutiert, wie der Bewegungsmodus geschätzt werden kann. Ein kombinierter Klassifikator würde den Bewegungsmodus schätzen und dann den Bewegungszustand bestimmen. Da eine solche Kombination den vorliegenden Erkenntnissen keine Neuigkeiten hinzufügen würde, wurde auf die Darstellung aus Umfangsgründen verzichtet.

4.4.2 Theoretische Charakteristika der Bewegungsmodi

Gemäß der Ausführungen zu Fahrzeugschwingungen im Abschnitt 2.2.3 und Schwingungen auf Grund der menschlichen Bewegung im Abschnitt 2.2.4 wird deutlich, dass die Signale der unterschiedlichen Modi auf Grund ihrer Entstehungsweise unterschiedliche Charakteristika aufweisen müssen. So liegen die Schwingungen bei menschlicher Bewegung in einem niedrigeren Frequenz- und einem höheren Amplitudenbereich als Fahrzeugschwingungen. Weiterhin unterscheiden sich

Straßenbahn- von Bussignalen auf Grund der unterschiedlichen Anregungsursache bezüglich Untergrund (bei Straßenbahn Stahl auf Stahl gegenüber Gummi auf Asphalt oder Kopfsteinpflaster) und Antrieb (bei Straßenbahn Elektromotor gegenüber Diesel- oder Hybridmotor im Bus).

Damit ergeben sich die in der Tabelle 4 dargestellten theoretischen Charakteristika bei der Analyse von Bewegungssignalen unterschiedlicher Bewegungsmodi.

Tabelle 4: Theoretische Charakteristika der betrachteten Bewegungsmodi

Bewegungsmodus	Lageparameter	Streuungsparameter	Spektrale Parameter
Stand	x, y, z zentriert um 0	minimal (Sensorrauschen)	minimale Amplituden unabhängig von der Frequenz
Zu Fuß	x, y, z zentriert um 0	Größte Streuung im Vergleich zu den anderen Bewegungsmodi	Hauptsächlich tieffrequente Schwingungen mit großer Amplitude
Bus	Abhängig vom Bewegungszustand zeitweilig außerhalb der Nulllage für x, y, z	Streuung geringer als zu Fuß, tendenziell höher als während einer Straßenbahnfahrt	Höhere Frequenzen als zu Fuß, bei weniger Energiegehalt als zu Fuß, höherer Energiegehalt als bei Straßenbahnfahrt
Straßenbahn	Abhängig vom Bewegungszustand zeitweilig außerhalb der Nulllage für x, y, z	Streuung höher als im Stand, tendenziell geringer als während Busfahrt	Höhere Frequenzen als zu Fuß, bei weniger Energiegehalt als zu Fuß, geringerer Energiegehalt als bei Busfahrt

4.4.3 Signalanalyse

Analog zu den Fahrzeug- und Personendaten wurden für die synthetischen Messreihen, die deRFnode-Daten aller drei Messreihen gemäß der Reisekette im Abschnitt 2.4.2 vereinigt, die im Abschnitt 3.4.3 gelisteten Merkmale für jeweils eine Sekunde lange Signalausschnitte für die drei Signalachsen berechnet. Die zugehörigen Boxplots aller betrachteten Merkmale sind in Anhang H zu finden.

Dem Vorgehen bei der Fahrzeug- und Personendatenanalyse folgend, können für diese Merkmale je Signalachse die Korrelationsmatrizen (siehe Abbildung 56) erstellt werden. Diese zeigen für jede Signalachse eine eigene Korrelationsstruktur:

- in der x -Achse existieren wie bei den Fahrzeugdaten mittelwertkorrelierte, streuungskorrelierte und (quasi-) unabhängige Merkmale
- in der y -Achse gibt es mittelwert- und gleichzeitig streuungskorrelierte Merkmale sowie (quasi-) unabhängige Merkmale

- in der z -Achse existieren wie in x mittelwertkorrelierte, streuungskorrelierte und (quasi-) unabhängige Merkmale. Mittelwert und Streuung sind negativ korreliert.

Insgesamt fällt die sehr hohe Korrelation zwischen den Merkmalen auf.




Abbildung 56: Korrelationsmatrizen für deRFnode-Daten eines Zyklus unterschiedlicher Bewegungsmodi

Gemäß den Ausführungen zu theoretischen Signalcharakteristika der einzelnen Bewegungsmodi sollten streuungskorrelierte Merkmale eine gute Information über die Trennbarkeit der Modi enthalten. In Abbildung 57 sind daher exemplarisch für die Merkmale Varianz und Mittlere Prominenz die Boxplots dargestellt.

Die Diagramme zeigen, dass die Modi auf Basis des x - und des z -Signals gut trennbar sind. Insgesamt sind die aus den Merkmalen Varianz und Prominenz generierten Informationen – wie zu erwarten – ähnlich. Allerdings sind die Überlappungsbereiche im Fall der Varianz zwischen den Bewegungsformen zu Fuß und den übrigen Modi geringer als bei der Betrachtung der Werte mittels mittlerer Prominenz. Dem gegenüber steht der geringere Überlappungsbereich zwischen Bus und Straßenbahn für die Betrachtung der Signale auf Basis der mittleren Prominenz.

Zusammenhänge zwischen den Signalen der drei Achsen

Wie für die Fahrzeug- und Personenbewegungssignale wurde für die Bewegungsmodus-deRFnode-Daten untersucht, inwieweit die Merkmale über die drei Signalachsen hinweg korrelieren (siehe Abbildung 58).

Im Vergleich zu den Analysen der Fahrzeug- und Personenbewegungsdaten fällt eine hohe Korrelation über alle drei Achsen hinweg auf. Am höchsten ist die Korrelation für die streuungskorrelierten Merkmale zwischen x und z -Achse. Genauso wie bei den Personenbewegungsdaten wird die Klassifikation daher lediglich für das z -Signal durchgeführt.

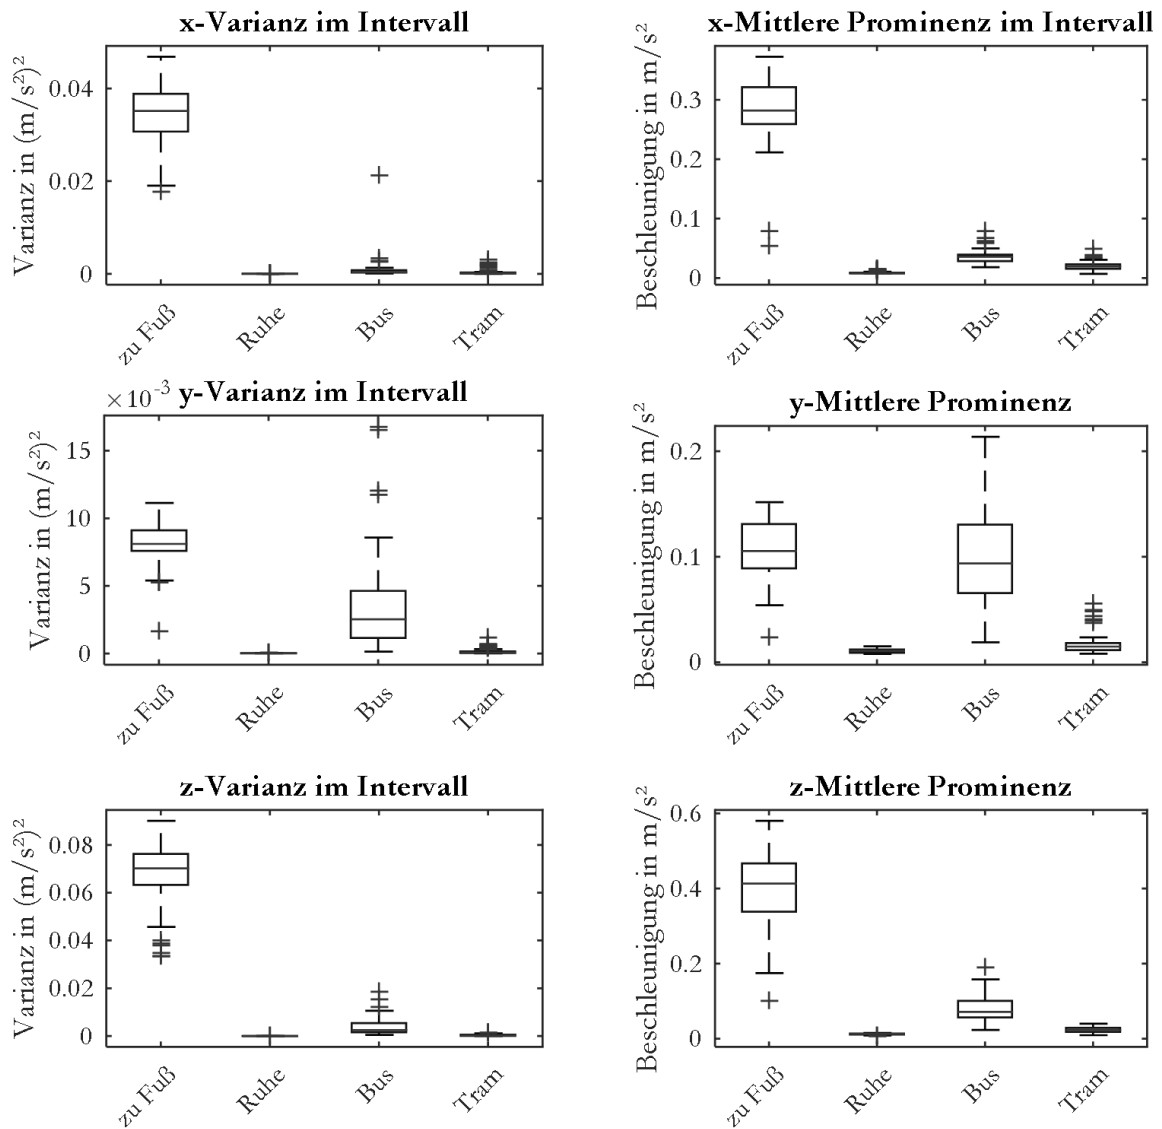


Abbildung 57: Boxplots für Varianz und mittlere Prominenz je Intervall für alle drei Achsen der deRFnode-Daten eines Zyklus unterschiedlicher Bewegungsmodi




Abbildung 58: Absolute Korrelationskoeffizienten zwischen den Merkmalen der drei Achsen für deRFnode-Daten eines Zyklus unterschiedlicher Bewegungsmodi

Ableitung des heuristischen Entscheidungsbaums

Ausgehend von der Signalanalyse wird zur Klassifikation der Bewegungsmodi der in Abbildung 59 dargestellte Entscheidungsbaum vorgeschlagen, der zum einen auf Basis von Varianz-Schwellwerten und zum anderen anhand eines Schwellwerts der mittleren Prominenz der lokalen Maxima im Intervall über die Zuordnung eines Intervalls zu einem Modus entscheidet.

Die Klassifikation erfolgt auf Basis des \tilde{x} -Signals anhand der Schwellwerte min_Laufen für Laufen, min_Bus für Bus, max_Ruhe für Ruhe und min_p_Bus zu Unterscheidung von Bahn und Bus.

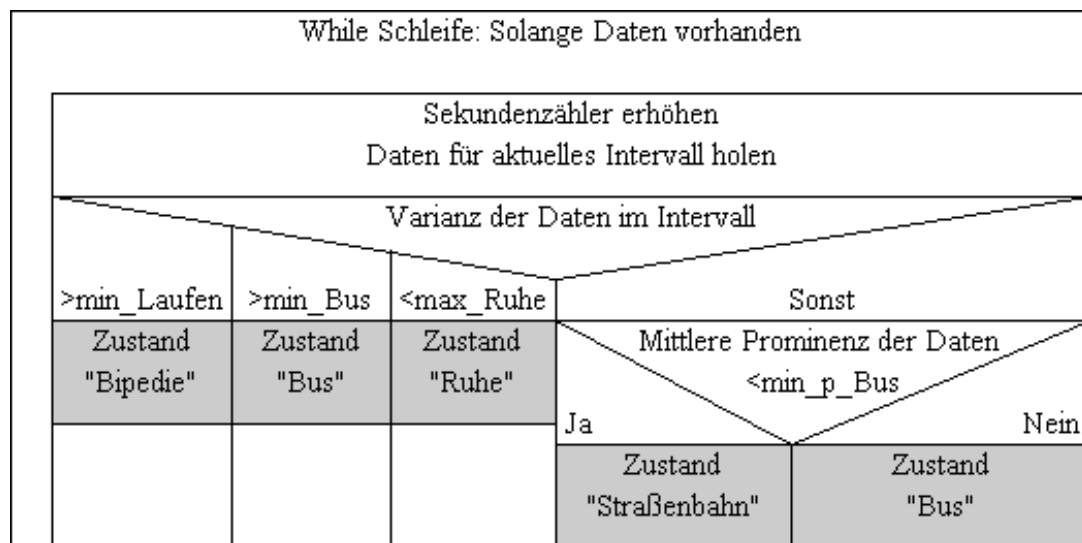


Abbildung 59: Entscheidungsbaum zur Klassifizierung von Bewegungsmodi

4.4.4 Ermittlung des Trainingsfehlers

Gemäß dem Vorgehen zur Bewertung der Fahrzeug- und Personenbewegungsklassifikatoren wurde für die Bewegungsmodi-Klassifikatoren der Trainingsfehler bestimmt. Genauso wie für die Klassifizierung der Personenbewegungen wird für die Bewegungsmodusbestimmung nur eine Signalachse verwendet. Für diese Achse wurde für alle drei bisher besprochenen Klassifikatortypen (Entscheidungsbaum (in Abbildung „DT“), linearer (in Abbildung „lin“) und quadratischer Diskriminanzanalyse-Klassifikator (in Abbildung „qud“) ein Klassifikator und ein HMM-Filter (in Abbildung „+HM“) erstellt. Diese für das Training der Klassifikatoren und Filter verwendeten Daten wurden anschließend zum Test genutzt und geben so, wie für die Fahrzeug- und Personenbewegungsklassifikatoren erläutert, Aufschluss über eine obere Schranke der erreichbaren Klassifikationsgüte für die jeweilige Klassifikatorvariante. In der Abbildung 60 ist die Korrektheit als Anteil der richtigen Entscheidungen an allen getroffenen Entscheidungen für die betrachteten Klassifikatoren dargestellt. Als Vergleichsmaßstab dienen die zwei Wahrscheinlichkeiten für die Korrektheit der diskutierten einfachen Klassifikatorvarianten bei Annahme einer Gleichverteilung

der Zustände oder der Verwendung des Zustandes höchster Häufigkeit im Trainingsdatensatz. Für die Diskriminanzanalyse ist das Ergebnis der Klassifikation dargestellt.

Alle Klassifikatorvarianten ordnen die zu klassifizierenden Intervalle mit einer über den Vergleichsschranken liegenden Korrektheit zu. Die Korrektheit der Klassifikatorvarianten differiert um 10,3 Prozentpunkte - der Diskriminanzanalyseklassifikator mit quadratischer Diskriminanzfunktion besitzt mit 98,5% die höchste Korrektheit, gefolgt von dem Entscheidungsbaumklassifikator mit 90,5% und dem in der gleichen Größenordnung liegenden Diskriminanzanalyseklassifikator mit linearer Diskriminanzfunktion mit 88,2%. Die Ergebnisse der Diskriminanzanalyseklassifikation sind unabhängig von der gewählten Signalachse (hier x -Achse dargestellt).




Abbildung 60: Trainingsfehler der Bewegungsmodus-Klassifikatorvarianten (Entscheidungsbaum (DT), Diskriminanzanalyse mit linearer (lin) oder quadratischer (qud) Diskriminanzfunktion, ggf. mit HMM-Filterung (HM)) verglichen mit Güteschranken

Die HMM-Filterung beeinflusst die Klassifikationsleistung im Falle einer linearen Diskriminanzfunktion für einen Diskriminanzanalyseklassifikator positiv (2,6 Prozentpunkte höher). Im Fall des Entscheidungsbaumklassifikators nimmt die Korrektheit um 0,4 Prozentpunkte ab. Für die quadratische Diskriminanzfunktion ergibt sich keine Veränderung in der Korrektheit. Die nicht dargestellten Korrektheiten für die Klassifikatoren samt HMM-Filterung auf Basis der x - und y -Signale differieren um maximal 4,5 Prozentpunkte nach unten für die lineare Diskriminanzfunktion und um 5,4 Prozentpunkte nach unten bzw. um 1,1 Prozentpunkte nach oben für die quadratische Diskriminanzfunktion.

4.4.5 Ermittlung des Generalisierungsfehlers

Zur Bewertung der Generalisierungsfähigkeit der getroffenen Aussagen wurden die in der zusammengesetzten Messkampagne gesammelten Daten verwendet. Es erfolgte somit das Training mit einer künstlich erzeugten Reisekette während das Testen mit einer real aufgenommenen Reisekette erfolgte. Für beide Reiseketten wurden andere Fahrzeuge und eine andere Befestigung des Sensors verwendet.

Alle Klassifikator-Varianten einschließlich der HMM-Filter-Varianten liegen, wie in Abbildung 61 gezeigt, mit ihrer Korrektheit über den vorgegebenen Güteschranken. Wie für den Fall der Fahrzeugbewegungen weist der Entscheidungsbaumklassifikator (in der Abbildung gekennzeichnet mit „DT“) die beste Generalisierungsfähigkeit auf. Dieser Klassifikator verwendet das \ddot{x} -Signal als Entscheidungsgrundlage. Der Klassifikator auf Basis der Diskriminanzanalyse wurde für alle drei Signalachsen getestet – hier dargestellt ist die beste Diskriminanzanalyse-Variante auf Basis des y -Signals. Die so erreichbare Korrektheit liegt für diese y -Signal-Variante 12,6 % über der \ddot{x} -Signal-Variante für die lineare (in der Abbildung gekennzeichnet mit „lin“) und 12,2% über der \ddot{x} -Signal-Variante für die quadratische Diskriminanzfunktion (in der Abbildung gekennzeichnet mit „qud“).




Abbildung 61: Generalisierungsfehler der Bewegungsmodus-Klassifikatorvarianten (Entscheidungsbaum (DT) auf \ddot{x} -Signal, Diskriminanzanalyse mit linearer (lin) oder quadratischer (qud) Diskriminanzfunktion auf y -Signal, ggf. mit HMM-Filterung (HM)) verglichen mit Güteschranken

Die HMM-Filterung bewirkte für den Entscheidungsbaumklassifikator und für den Diskriminanzanalyseklassifikator mit quadratischer Diskriminanzfunktion übereinstimmend eine Verbesserung um 1,3%. Für die lineare Diskriminanzfunktion ergab sich keine Veränderung.

4.5 Schlussfolgerungen zur Identifizierbarkeit von Bewegungszuständen

Zur Beantwortung eines Teils der im Unterkapitel 2.7 aufgestellten Leitfragen zu dieser Arbeit werden in diesem Abschnitt die Ergebnisse der in diesem Kapitel durchgeführten empirischen Untersuchungen zusammengefasst und bewertet.

Welche Nutz- und Störsignalquellen sind in einer ÖPV-Umgebung bei der Erfassung von Bewegungszuständen auf Basis von Beschleunigungssignalen, die mittels mobiler Endgeräte erfasst werden, relevant?

Die Signalanalyse zeigte mittelwertkorrelierte Merkmale und streuungskorrelierte Merkmale. Wiederum gibt es Zustände, die über mittelwertkorrelierte Merkmale identifizierbar sind und Zustände, die eher über streuungskorrelierte Merkmale identifizierbar sind.

Zu ersterer Gruppe zählen Fahrzeugbewegungszustände in x - und y -Achse, die mit dem Antrieb, dem Beschleunigungs-/Bremsvermögen, sowie mit der Kurvenlage verbunden sind. Antrieb und Kurvenlage sind demnach Nutzsignalquellen. Hierbei ist zu beachten, dass solche Zustände eine sorgfältige Kalibrierung des Signalmittelwerts benötigen. Ein Nullpunktfehler, der aus fehlerhafter Verbindung mit dem Fahrzeugkoordinatensystem oder Temperaturschwankungen resultiert, kann so als Störsignalquelle betrachtet werden.

Zu der Gruppe der Zustände, die über streuungskorrelierte Merkmale identifizierbar sind, gehören diejenigen Zustände, die auf Basis des \tilde{x} -Signals bestimmbar sind. Für die Fahrzeugbewegungen sind dies die Unterscheidung in Halt und Fahrt, sowie die Unterscheidung der Fahrt auf glattem oder holprigem Untergrund. Personenbewegungen können grundsätzlich über das \tilde{x} -Signal klassifiziert werden. Dies ist auch für die Bewegungsmodusunterscheidung möglich. Nutzsignalquellen sind damit der variierende Fahrzeug-Untergrund-Kontakt bei Bewegung eines Fahrzeugs und der menschliche Körper bei Bipedie. Da die Streuung theoretisch unabhängig vom Mittelwert ist (Korrelation ist dennoch, wie gezeigt, möglich), ist eine Kalibrierung des Nullpunktfehlers irrelevant. Die wesentliche Störsignalquelle ist hier die Bewegung des menschlichen Körpers, wenn eine Fahrzeugbewegung mittels eines am Körper befestigten Sensors betrachtet werden soll, da diese Bewegung die Fahrzeugbewegung überlagert.

Welche Bewegungszustände können über die Entscheidung für ein Verkehrsmittel hinaus in einer ÖPV-Umgebung erfasst werden?

Diese Frage wurde für die einzelnen Verkehrsmittel und den damit erstellten Messungen im Abschnitt 4.1.3 einzeln gestellt.

Es lässt sich über alle Bewegungsmodi hinweg zusammenfassen, dass die Zustände und Modi, wie sie in dem Unterkapitel 3.3 vorgeschlagen wurden, prinzipiell identifizierbar sind.

Weiterhin konnte festgestellt werden, dass diese Zustandserkennung für die Messstraßenbahndaten und die deRFnode-Daten möglich ist. Dieses System eignet sich demnach bei geeigneter Befestigung an einem Fahrzeug als Referenzsystem.

Die mit diesem System aufgenommenen Daten können zum Aufbau von Fahrzeugbewegungsklassifikatoren verwendet werden. Die so erzeugten Klassifikatorstrukturen sind auf Daten verallgemeinerbar, die mit einem an einer Person befestigten Sensor aufgenommen wurden. Dies gilt auch für die Bewegungsmoduserkennung.

Bei der hier vorliegenden Datengrundlage ergab sich eine unterschiedliche Generalisierungsfähigkeit. Diese Übertragbarkeit ist zum einen von dem Prinzip der Klassifikatorerzeugung abhängig und zum anderen von der Allgemeingültigkeit des verwendeten Datensatzes. Im Fall zu kleiner Datengrundlagen wurden Merkmale im Trainingsfall zu spezifisch gelernt. Dies betrifft die Diskriminanzanalyse, bei der die Merkmalsverteilungen auf Grundlage der vorliegenden Trainingsdaten geschätzt werden. Bilden diese Merkmalsverteilungen nur einen Teil der wahren zu Grunde liegenden Verteilung ab, ist eine spätere Zuordnung von Testdatensätzen nur eingeschränkt möglich. Bei heuristischen Entscheidungsbäumen kann diesem Effekt durch Verwendung von Metawissen unter Umständen entgegengewirkt werden. Es wird daher empfohlen, für jede der im Abschnitt 4.1.3 angesprochenen Detailfragestellungen die Datengrundlage zu vergrößern.

Es wurde weiterhin diskutiert, dass ein geschichtetes Vorgehen bei einer kleinen Lerndatenbasis sinnvoll ist.

Wie können Beschleunigungssignale für reproduzierbare Anwendungstests in einer Laborumgebung wiedergegeben werden?

Die Signalanalyse zeigte eine gute Klassifikation von Bewegungszuständen und -modi auf Basis des \ddot{x} -Signals. Dieses Signal ist in einem Labor mittels Schwingtischen erzeugbar.

Es ist also davon auszugehen, dass die Entscheidungen auf Basis in einer Fahrzeugumgebung gemessenen Daten in einer Laborumgebung reproduzierbar sind.

5 Reproduktion von Bewegungen in einer Laborumgebung

Dieses Kapitel zeigt auf, wie aufgenommene Beschleunigungssignale in einer Laborumgebung wiedergegeben werden können und so für reproduzierbare Tests genutzt werden können.

5.1 *Location Based Services in-the-loop*

Wie in [Partzsch et al. 2014a] dargestellt, müssen für die Entwicklung von Navigationsanwendungen, wie z. B. SMART-WAY [Tönjes et al. 2012]) oder NADINE ([Partzsch et al. 2013c]), üblicherweise eine Reihe Tests durchgeführt werden. Wenn diese Versuche im realen Verkehrsablauf erfolgen, sind diese auf Grund von Randbedingungen zeitaufwändig (Abhängigkeiten von Fahr-/Dienstplänen) und bei Verwendung spezieller Verkehrsträger oder Verkehrsstrassen kostspielig. Hinzu kommt, dass diese Tests unter keinen Umständen reproduzierbar oder repräsentativ sein können, da die Signalausbreitung (z. B. Konstellation der Ortungssatelliten globaler Satellitennavigationssysteme (engl. global navigation satellite systems, GNSS), Signalausbreitungseigenschaften der Übertragungsmedien, Abschattung, Mehrwegeausbreitung) und die Verkehrssituation (veränderliches Verkehrsaufkommen, Infrastrukturverfügbarkeit) ständiger Veränderung unterliegt.

Eine Lösung dieser Probleme ist der „Location Based Services in-the-loop“-Ansatz. Der „in-the-loop“-Ansatz ist in der Automobilindustrie bekannt, bei dem ein Bauteil getestet werden kann, in dem dessen Umgebung an dessen Schnittstellen simuliert wird und heißt dort „Hardware in-the-loop“. Dieser Idee folgend kann eine ortsbezogene Anwendung (engl. Location Based Service, LBS) derart getestet werden. Ein mobiles Endgerät mit einer LBS-Anwendung kann in einer Laborumgebung mit allen relevanten Signalen der Umgebung von den niederfrequenten Beschleunigungs- und Drehratensignalen bis hin zu hochfrequenten GNSS-Signalen beaufschlagt werden [Partzsch et al. 2014a]. Nach von Hünerbein et al. (2013) gibt es zwei Strategien, erstens die vollständige Signalsimulation und zweitens die Aufnahme und Wiedergabe von Signalen („Record/Playback“). Für den Bereich von GNSS-Signalen wird dieses Vorgehen untersucht und genutzt [Michler et al. 2013, Richter et al. 2013].

In einer integrierten Laborumgebung kann dieses Konzept die über die GNSS-Simulation hinaus erweitert werden. Dieses Konzept ermöglicht, die zu entwickelnde Navigationsanwendung „in-the-loop“ zu testen, indem Umfeldsignale (Ortungssignale, wie GPS und WLAN-Beacons, Inertialsensoriksignale (INS), wie Beschleunigungen und Drehraten, sowie Kommunikationssignale, wie GPRS) reproduzierbar auf das mobile Endgerät aufgeprägt werden können und gezielte Szenarios wiederholbar untersucht werden können [Partzsch et al. 2013c], [Partzsch et al. 2014a].

Abbildung 62 zeigt das Konzept der LBS in-the-loop Umgebung samt Signalsimulation und Kommunikation mit dem Hintergrundsystem (z. B. Fahrplanauskunft, Ticketing). Mit Hilfe einer Nutzeroberfläche können die navigationsrelevanten Entscheidungen einer Person sowie Verkehrsprozessinformationen, wie z. B. Verzögerungen, von einer Bedienperson an das System übermittelt werden. Diese Informationen führen zu einer automatischen Anpassung der Signalsimulation.

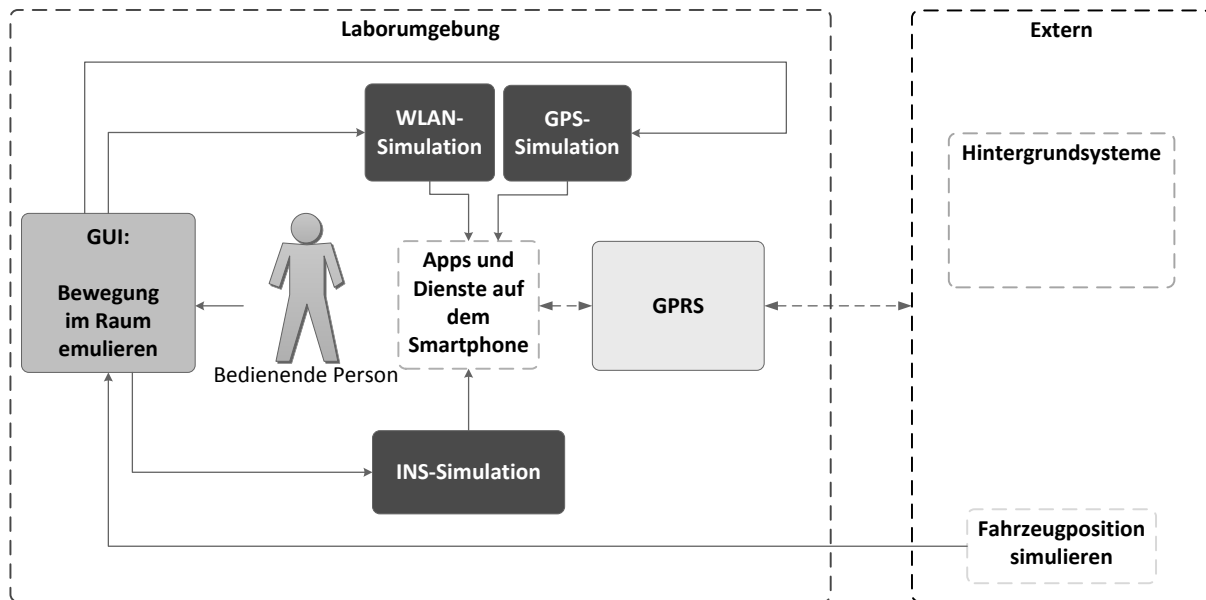


Abbildung 62: Location Based Services in-the-loop Umgebung (nach Partzsch et al. 2014a)

Der folgende Abschnitt befasst sich mit der Ausgestaltung der Simulation von Bewegungsmustern, speziell Beschleunigungssignalen.

5.2 Laborkonzept zur Reproduktion von Bewegungsmustern

Die Reproduktion von Messfahrten wird an der Professur „Informationstechnik für Verkehrssysteme“ der TU Dresden erforscht. Kern dieser Innovation ist die synchrone Aufnahme und Wiedergabe von Signalen zur Ortung von Verkehrsmitteln und deren Kommunikation. Eine Messfahrt kann nun z.B. für den Vergleich von Ortungssensoren exakt wiederholt werden, was außerhalb eines Labors auf Grund veränderlicher zufälliger Umwelteinflüsse so nicht möglich wäre. [Heidrich et al. 2013, Michler et al. 2013, Michler et al. 2014]. Ein Teil dieser Laborumgebung ist die Reproduktion von Bewegungsmustern. Sie ist, wie in Abbildung 63 gezeigt, das Gegenstück zu der in dieser Arbeit dargestellten durchgängigen Signalerkennung ab Analyse des Schwingungssystems bis hin zur Nutzung der Muster in einer Navigationsanwendung.

Eine steuerbare Aktorik bildet die Grundlage für eine solche Bewegungsmusterreproduktion. Wie im vorangegangenen Unterkapitel diskutiert, existieren zwei Wege, wie die Ansteuerung umgesetzt werden kann: die Simulation auf Basis von Modellannahmen für ein Mehrkörpermodell und das

Aufnehmen und Wiedergeben („Record/Playback“). Analog zur GNSS-Reproduktion in [Michler et al. 2013] wird im Rahmen dieser Arbeit diskutiert, ob dieser Ansatz auch für die Reproduktion von Bewegungssignalen geeignet ist.

Nach Iwnicki (2006) liegt ein wesentlicher Teil der Vibration – und damit der Information – während der Bewegung in Richtung der z -Achse an. Exemplarisch für alle anderen Achsen wurde das hier vorgestellte Konzept daher für die Beschleunigung in Richtung der z -Achse ausgeführt.

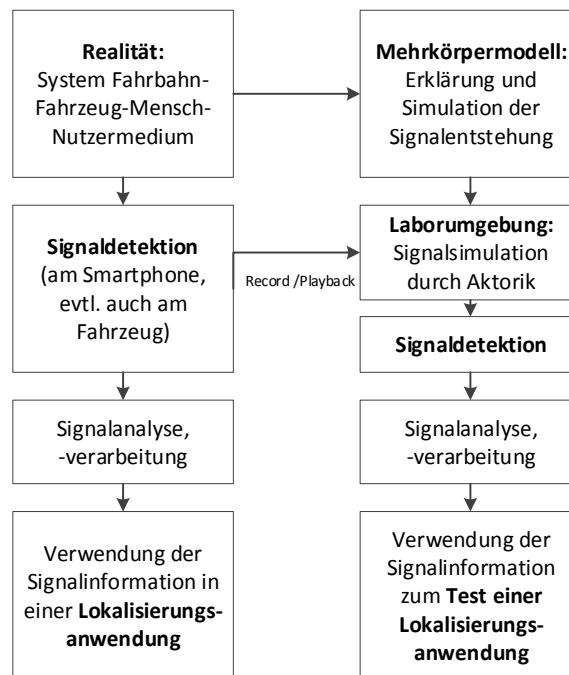


Abbildung 63: Laborkonzept zur Schwingungssignalreproduktion (nach Partzsch 2013d)

Das System [Eltzschig 2014] besteht aus einer Kombination aus Aufnahmesensor und Wiedergabeeinheit (siehe Abbildung 64), um eine automatische Kalibrierung [Gierisch et al. 2015] zu erreichen.

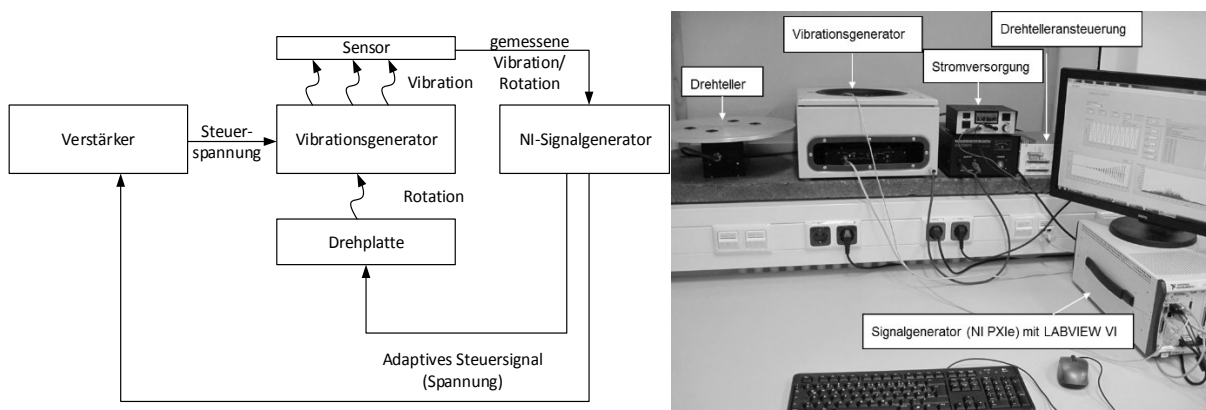


Abbildung 64: Aktorikkonzept und Umsetzung (nach Partzsch et al. 2014b)

Zur Aufnahme der Signale können die im Kapitel 4.1.2 vorgestellten Messsysteme genutzt werden [Partzsch et al. 2014c].

Die Wiedergabe erfolgt mit einem Vibrationsgenerator bestehend aus Lautsprechermembran und Verstärker. Dieses System kann mit einem Drehteller zur Generierung von Rotationen um die z -Achse gekoppelt werden. Das System ist in der Lage, die in Abschnitt 2.2.3 und 2.2.4 dargestellten maßgeblichen Frequenzen von 0 bis 30 Hz und typische Fahrzeugschwingungsamplituden bis 1 cm abzubilden.

Eine Systemkalibrierung ist auf Grund der Masse- und Geometrieabhängigkeit bei jeder Änderung (z.B. Sensorhalterung) und Änderung des im Test befindlichen Endgeräts notwendig.

5.3 Übertragungseigenschaften des Systems

Dieser Abschnitt befasst sich mit dem Übertragungsverhalten des Schwingungssystems bei Verwendung von Sinussignalen und realen Signalen einer Busfahrt.

5.3.1 Vorversuche mit Sinussignalen

In den von Partzsch et al. (2014b) dargestellten Versuchen wurde festgestellt, dass in dem für diese Arbeit wesentlichen Frequenzbereich von 0 bis 30 Hz keine frequenzunabhängige Übertragungsfunktion des Systems angenommen werden kann, wie in Abbildung 65 exemplarisch für einzelne Frequenzen im Bereich von 1 bis 29 Hz in 1 Hz-Schritten gezeigt. Bei konstantem Effektivwert der Steuerspannung (0,8 V) verändert sich je nach Steuerfrequenz die mit dem auf dem Schwingungsgenerator befestigten Sensor gemessene Beschleunigung. Ein Resonanzbereich ist bei 21 bis 25 Hz zu vermuten.




Abbildung 65: Vorversuch: Aufnahme eines Signals aus einzelnen Frequenzen im Bereich von 1 bis 29 Hz bei konstantem Effektivwert der Steuerspannung (nach Partzsch et al. 2014b)

Zur Charakterisierung des Übertragungsverhaltens wurde untersucht, bei welcher Frequenz welche Steuerspannung benötigt wird, um eine vorgegebenen maximale Auslenkung (1 cm) zu erreichen.




Abbildung 66: Bestimmung der benötigten Spannung zum Erreichen einer vorgegebenen maximalen Auslenkung (1 cm)

Das Ergebnis ist in Abbildung 66 dargestellt. Zur Vermeidung von Überlast an der Spule des Schwingungsgenerators wurde der Versuch auf 0,8 V für Schwingungen bis 25 Hz begrenzt.

Für sehr kleine Frequenzen bis 0,5 Hz waren keine Schwingungen sichtbar. Im vorher überschlägig ermittelten Resonanzbereich um 15 Hz wurde zur Bestimmung der Resonanzfrequenz eine höhere Frequenzauflösung gewählt.

Das nachfolgende Unterkapitel diskutiert die Wiedergabeeigenschaften des Systems hinsichtlich der für den Test von Navigationsfunktionen relevanten Personen- und Fahrzeugsignale.

5.3.2 Reale Signale

Für die Bewertung des Übertragungsverhaltens bei der Wiedergabe realer Signale wurde ein Ausschnitt der im Abschnitt 4.1.3 beschriebenen Bus-Messfahrt mit dem System abgespielt und mit dem deRFnode aufgenommen. Für einen als quasistationär betrachteten Geradenfahrabschnitt auf glattem Untergrund und einen Standabschnitt wurde nun das Amplitudenspektrum verglichen und die zugehörige Übertragungsfunktion berechnet (siehe Abbildung 67).

Wie zu erwarten, unterscheiden sich die Amplitudenspektren für Fahrt und Stand, wenn man die beiden Originalsignale betrachtet, und, wenn man die beiden Wiedergabesignale betrachtet (auf Grund des gleichen Achsenbereichs in y ist das Originalsignal bei Stand fast nicht zu erkennen). Der Unterschied zwischen Original und Wiedergabe ist für den Fahrt- und den Standabschnitt erkennbar. Für beide Abschnitte fällt die Überhöhung im Bereich 15-35 Hz auf. Dies deckt sich mit den Erkenntnissen zu den Sinus-Signalen im Vorversuch. Im Fahrabschnitt fällt außerdem auf, dass niedrige Frequenzen im Bereich 0-7 Hz systembedingt gedämpft wiedergegeben werden. Dies ist ebenfalls auf Grund der Ergebnisse der Vorversuche zu erwarten.

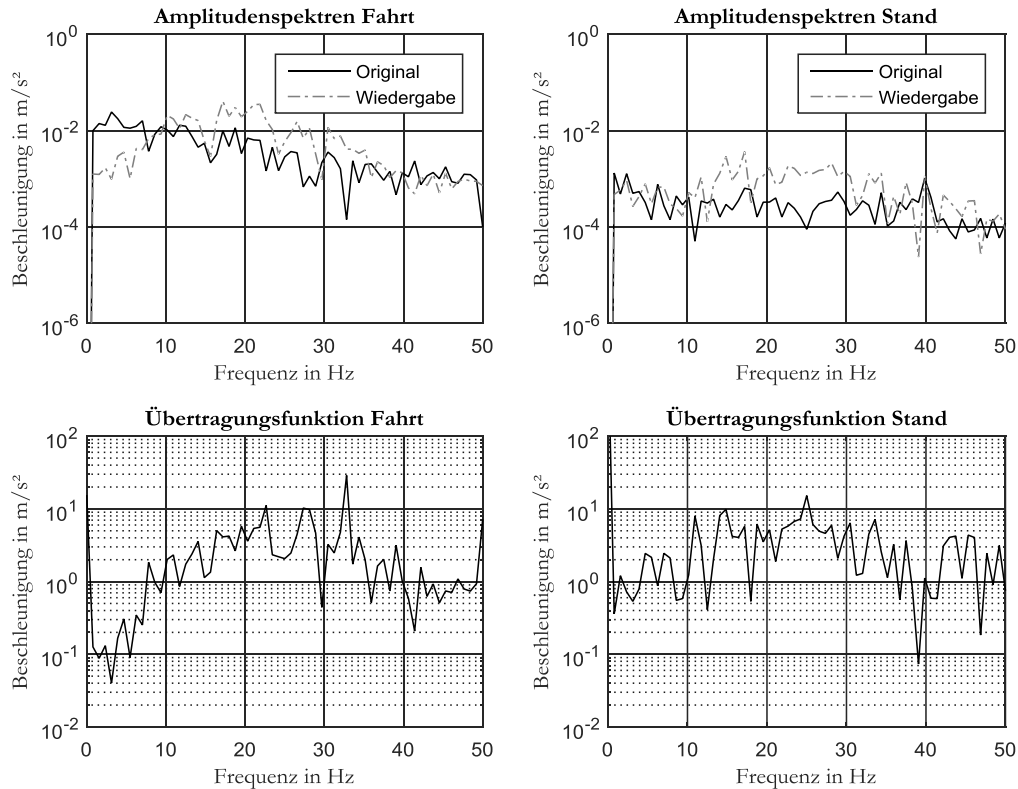


Abbildung 67: Spektrenvergleich und empirische Übertragungsfunktion

Sucht man nun in den Übertragungsfunktionen einen Bereich, der für beide Fahrtzustände einen Wert nahe 1 (10^0) aufweist, sodass die Amplituden in gleicher Größe wiedergegeben werden, dann kommen die Bereiche zwischen 8-12 Hz und 40-50 Hz in Frage. Da relevante Fahrzeug- und Personenschwingungen gemäß der Ausführungen in den Abschnitten 2.2.3 und 2.2.4 im Bereich 8-12 Hz zu finden sind, werden nachfolgende Untersuchungen auf diesen Bereich beschränkt.

5.4 Reproduktion von Klassifikatorentscheidungen

In diesem Unterkapitel wird exemplarisch für die im Abschnitt 4.1.3 beschriebene Bus-Messfahrt gezeigt, dass Klassifikatorentscheidungen mit Hilfe von künstlich erzeugten Signalen reproduzierbar sind.

5.4.1 Signalanalyse

Der im Abschnitt 4.2.6 vorgestellte Entscheidungsbaum zur Klassifikation von \ddot{x} -Signalen basierte auf der Varianz des Zeitsignals. Wie im Abschnitt 5.3.2 besprochen, erfolgt die Wiedergabe der Signale in begrenzten Frequenzbereichen derart, dass sie dem Originalsignal entspricht.

Analog zum Vorgehen in Kapitel 4 wurde eine Signalanalyse durchgeführt, um zu untersuchen, welche Signalmerkmale für Original- und Wiedergabesignal in dem angesprochenen Frequenzbereich (d.h. die Frequenzen 8,59/ 9,34/ 10,94 Hz) für die drei vorgegebenen Zustände ähnliche Wertebereiche liefern.

Das Merkmal „FFT-Koeffizientensumme“ ist ein mögliches Merkmal. Es wurde für das Original- und das Wiedergabesignal in der \tilde{x} -Achse auf Basis einer gefensterten 128-Punkte-FFT berechnet. Die Entscheidung für die 128 Punkte fiel auf Basis von Voruntersuchungen hinsichtlich sinnvoller Auflösung und notwendiger Rechenzeit. Es ergeben sich für die Zustände „glatt“, „holprig“ und „Stand“ die in Abbildung 68 dargestellten Boxplots.

Obwohl die Verteilungen variieren, ist es möglich, einen Entscheidungsbaum auf Basis dieser FFT-Koeffizientensummen zu entwerfen.

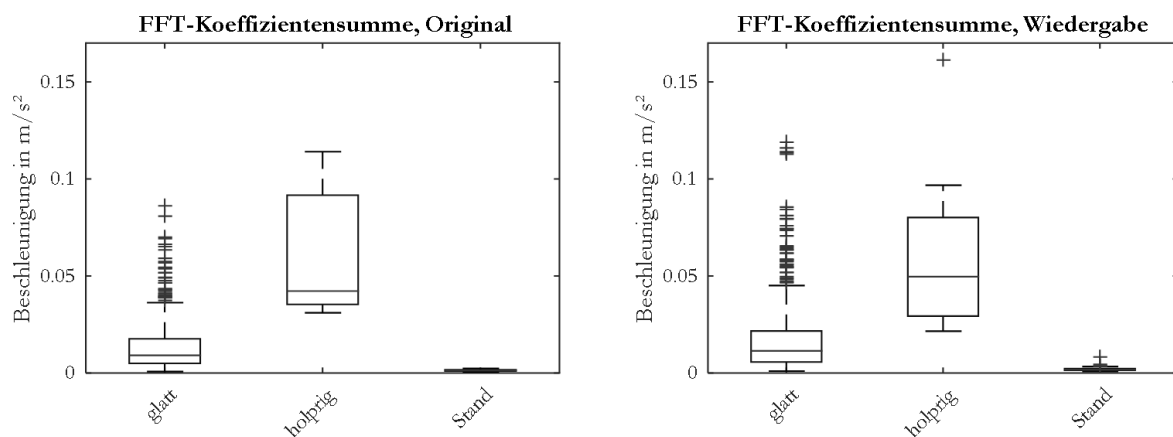


Abbildung 68: Absolute Summe der 12.-14. FFT-Koeffizienten

5.4.2 Aufbau eines Entscheidungsbaums

Ausgehend von der Signalanalyse des letzten Unterabschnitts wird zur Klassifikation der Bewegungszustände in der \tilde{x} -Achse ein Entscheidungsbaum vorgeschlagen (siehe Abbildung 69), der auf Basis der FFT-Koeffizientensumme aus dem 12., 13. und 14. Koeffizienten der 128-Punkte FFT des \tilde{x} -Signals eines Intervalls über die Zuordnung eines Intervalls zu einem Zustand entscheidet.

Zur Festlegung der benötigten Schwellwerte wurde die Klassifikatorstruktur sukzessive aufgebaut und numerisch anhand der Verwechslungsmatrix nach einem Optimum für das Originalsignal gesucht.

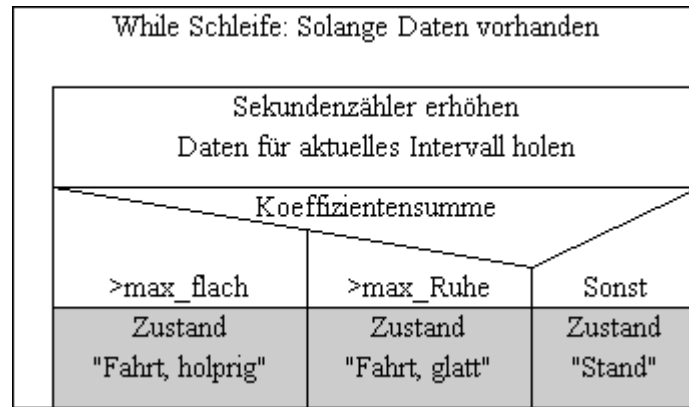


Abbildung 69: Neue Klassifikatorstruktur, die bei Signalreproduktion im Labor eine Klassifikation ermöglicht

5.4.3 Trainings- und Generalisierungsfehler

Gemäß des Vorgehens von Kapitel 4 soll der Trainings- und der Generalisierungsfehler bestimmt werden. Für diesen Versuch entspricht der Trainingsfehler demjenigen Fehler, der bei Klassifikation der Originaldaten entsteht. Der Generalisierungsfehler entsteht bei Klassifikation der Daten, die bei der Wiedergabe der Schwingungen aufgenommen wurden.

Stellt man für diesen Versuch nach Formel (14) die Verwechslungsmatrizen mit den Elementen $v(e,k)$ auf, deren Elemente, wie im Abschnitt 2.6.6 definiert, sich auf den klassifizierten Zustand e und den tatsächlichen Zustand k beziehen, erhält man folgende Struktur:

$$\begin{bmatrix} \text{Fahrt, glatt} | \text{Fahrt, glatt} & \text{Fahrt, glatt} | \text{Fahrt, holprig} & \text{Fahrt, glatt} | \text{Stand} \\ \text{Fahrt, holprig} | \text{Fahrt, glatt} & \text{Fahrt, holprig} | \text{Fahrt, holprig} & \text{Fahrt, glatt} | \text{Stand} \\ \text{Stand} | \text{Fahrt, glatt} & \text{Stand} | \text{Fahrt, holprig} & \text{Stand} | \text{Stand} \end{bmatrix}. \quad (19)$$

Für die Originaldaten ergeben sich diese Zahlenwerte für diese Elemente:

$$\begin{bmatrix} 543 & 0 & 69 \\ 9 & 0 & 0 \\ 0 & 0 & 150 \end{bmatrix}. \quad (20)$$

Dies entspricht einer Korrektheit von 89,9%.

Für die Wiedergabedaten ergibt sich die Matrix:

$$\begin{bmatrix} 555 & 0 & 57 \\ 8 & 1 & 0 \\ 25 & 0 & 125 \end{bmatrix}. \quad (21)$$

Dies entspricht der Korrektheit von 88,3%. Beide Klassifikationsergebnisse liegen über der oberen Güteschranke von 79%, die sich für die Busdaten in der \hat{x} -Achse ergab (siehe Abschnitt 4.2.8).

Bei der Analyse der Fehler fällt auf, dass Halt und Fahrt, glatt gut erkannt werden. Die holprige Fahrt kann nicht von glatten Fahrabschnitten getrennt werden.

Prinzipiell lassen sich Schwingungssignale also im Labor erzeugen. Es gibt Signalbereiche, die systembedingt gedämpft oder verstärkt werden und somit das Signal und damit mögliche Klassifikationsergebnisse verändern. Bei gezielter Auswahl der zur Klassifikation verwendeten Merkmals oder einer geeigneten Kalibrierung des Systems ist eine Klassifikation des Signals auf Basis von Wiedergabedaten genauso wie auf Basis von Originaldaten möglich. Eine mögliche Kalibrierung war Gegenstand der Veröffentlichung von Gierisch et al. (2015).

6 Anwendung von Bewegungsmusterklassifikatoren in standortbezogenen Diensten des ÖPV

Auf Basis der vorangegangenen Untersuchungen zur Bewegungsmusterklassifikation und -reproduktion diskutiert dieses Kapitel zwei Anwendungsfälle solcher Klassifikatoren.

Zunächst wird der Ansatz des logischen Map Matchings besprochen. Darüber hinaus können Beschleunigungsmuster und deren Klassifikation in anderen standortbezogenen Diensten des ÖPV, wie z. B. des automatischen Ticketings, verwendet werden.

6.1 Bewegungszustandsklassifikation für ÖPV-Navigationssysteme

Im Rahmen des EU-Projektes SMART-WAY wurde ein nahtloses ÖPV-Navigationssystem auf Basis von Smartphones entwickelt. Wie Tönjes et al. (2012) vorstellen, ist es mit Hilfe einer Smartphone-Applikation für die anwendenden Personen möglich, während einer Fahrt in einem ÖPV-System so zu agieren, wie sie es bei der Nutzung eines PKW-Navigationsgerätes bei einer Autofahrt gewöhnt sind. Ist das gewünschte Fahrtziel eingegeben, verfolgt die Applikation den aktuellen Standort der Person und gibt mit Hilfe einer Anbindung an das Echtzeit-Auskunftssystem des jeweiligen Verkehrsanbieters Auskünfte zur optimalen Fahrtroute. Ein spontanes Abweichen von der Route ist – wie bei der Nutzung eines PKW-Navigationssystems – jederzeit möglich.

Für eine solche Anwendung ist eine Karteneinpassung (engl. map matching) der aktuell gemessenen Position notwendig, also der korrekten Zuordnung einer Fahrzeug- oder Personenposition zu einem Netzwerksegment [Groves 2007]. Dieser Prozess kann gegebenenfalls die Positionierungsgenauigkeit verbessern, wenn geeignete Netzdaten vorhanden sind. [Quddus et al. 2007]. Ein möglicher Ansatz ist das wahrscheinlichkeitsbasierte Map Matching [Gerlach et al. 2009], der mehrere Sensorinformationsströme zulässt.

Solche Navigationssysteme basieren auf GPS-Ortungsinformationen, die – wie in der Einleitung dargestellt – nicht immer zur Verfügung stehen. Partzsch et al. (2011) entwickelten dazu einen multisensorbasierten Ansatz, der zusätzlich zu einem klassischen Map Matching auf Basis von Ortsinformationen eines funkbasierten Ortungssystems (GPS, WLAN oder andere Sensornetze) Sensorinformation von Beschleunigungssensoren einschließt und so eine verbesserte Ortsinformation ermöglicht (siehe Abbildung 70).

Für Fahruntergründe (z. B. Weichen, Kopfsteinpflaster) und zwingende Abfolgen von Fahrzeugzuständen (z. B. Kurvenfahrten, Halte) kann ein verorteter Musterkatalog aufgebaut werden. Auf

Basis der Sensorinformation einer Fahrt ist nun eine logische Zuordnung von Sensordaten auf eine Karte möglich. Dieses Vorgehen ist in [Partzsch et al. 2011] und [Partzsch et al. 2013] als logisches Map Matching bezeichnet worden und fällt nach Groves (2007) in die Klasse der feature-matching-Techniken (wie finger printing-Verfahren aus dem Bereich der WLAN-Ortung mittels Received Signal Strength Indication (RSSI) [Werner 2014]). Eine erste prinzipielle Anwendung zeigen Hua et al. (2015).



Abbildung 70: Multisensorbasierte Ortung (in Anlehnung an Partzsch et al. (2011))

In Abbildung 71 wird das Verfahren dargestellt. Es besteht aus einer Lern- und einer Positionierungsphase. In der Lernphase werden charakteristische Beschleunigungsmuster aufgenommen. Dies sollten Muster sein, die relevant für den Fahrgastraum eines Fahrzeugs sind, also die in Abbildung 16 gekennzeichneten Fahrzeugbewegungen.

Diese Beschleunigungsmuster müssen anschließend georeferenziert werden, also derjenigen Kartengrundlage zugeordnet werden, die später für die Positionierung verwendet werden soll. Zur Positionierung werden die aktuell gemessenen Beschleunigungsmuster verwendet. Unter Abgleich dieser Muster mit der Datenbank aus der Lernphase kann nun die Schätzung der Ortsposition erfolgen. Ein möglicher Ansatz ist der Multi-Hypothesen-Test [Gerlach et al. 2009].

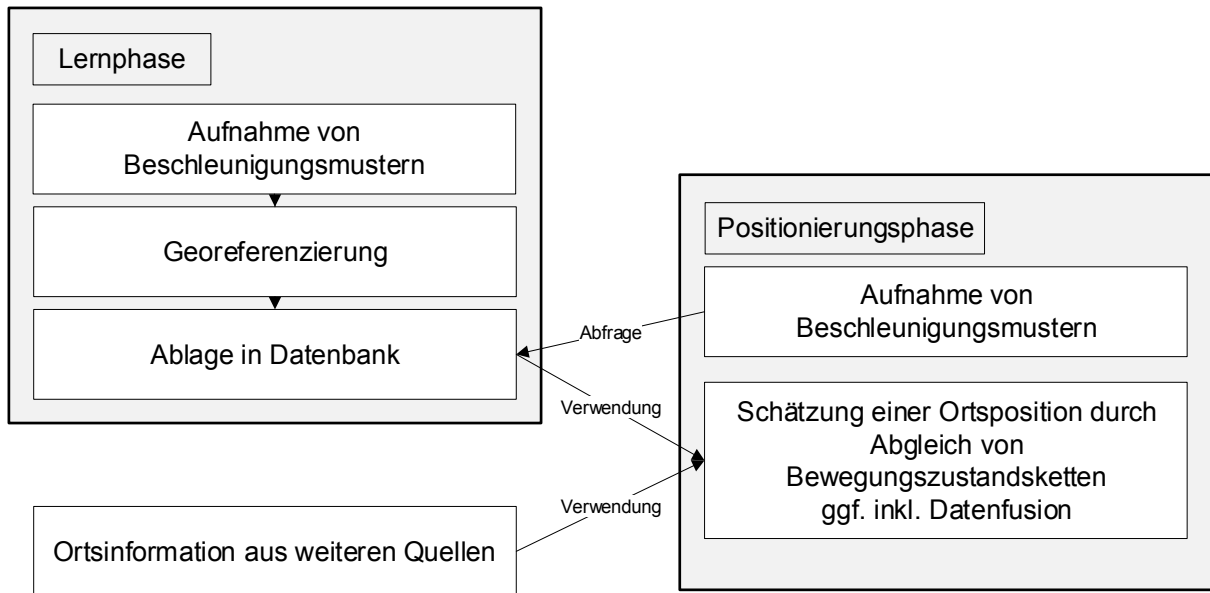


Abbildung 71: Logisches Map Matching

Die Wirkungsweise dieses Ansatzes kann mit Hilfe des nachfolgend beschriebenen Messstraßenbahnszenarios „Georgplatz“ beschrieben werden. An dieser Stelle im Dresdner Straßenbahnnetz existieren bei einer Fahrt in Richtung Süden zwei Möglichkeiten: erstens die Geradeausfahrt von Nord nach Süd entlang der St. Petersburger Straße und zweitens das Einbiegen vom Dr.-Külz-Ring in die St. Petersburger Straße. Es werden, wie in Abbildung 72 gezeigt, unterschiedliche Weichenkomponenten befahren, die in unterschiedlich starker Anregung des Wagenkastens resultieren. Die relevanten Weichenteile sind die zwei unterschiedlichen Herzstückspitzen. Befährt ein Rad eine Herzstückspitze mit einer Tiefrille liegt das gesamte Rad bei der Weichenüberfahrt auf. Bei einer Flachrillenherzstückspitze läuft das Rad lediglich auf dem Spurkranz. Hierbei treten gleichzeitig eine stärkere Beanspruchung des Rades und eine stärkere Erschütterung als bei einer Tiefrillenherzstückspitze auf. Dies zeigt sich in den messbaren Beschleunigungswerten, siehe Abbildung 72, rechts, auf. Im rechten Teil dieser Abbildung sind von 1000 Überfahrten in Richtung Süd (gerade Nord-Süd, abbiegend West-Süd) dieses Bereichs verortete Messungen der Messstraßenbahn exemplarisch für die x -Richtung (Fahrtrichtung) dargestellt. Die Höhe der Beschleunigung ist wie in der Legende angegeben farblich kodiert. Es fällt auf, dass bei der geraden Überfahrt von Nord nach Süd große Beschleunigungsspitzen auftreten, die sich mit der Überfahrt von Flachrillenherzstückspitzen erklären lassen [Partzsch et al. 2013a].

Ist auf Basis der aktuell gemessenen Beschleunigungen und damit des aktuell klassifizierten Beschleunigungsmusters bekannt, dass eine Straßenbahn eine Flachrillenherzstückspitze befährt, kann bei bekannter Fahrtrichtung gleisselektiv entschieden werden, dass sich die Bahn auf dem Geradeausgleis von Nord nach Süd befinden muss. Weitere Informationen, wie

z. B. die niedrige/erhöhte Querschleunigung können eine solche Hypothese stützen oder widerlegen. Dies kann auf Basis von GPS-Daten nicht möglich sein, wenn diese stark verrauscht oder lückenbehaftet sind.




Abbildung 72: Schienenschema und verortete Beschleunigungsmessungen bei Fahrt in Richtung Süd (in Anlehnung an Partzsch et al. (2013a))

6.2 Bewegungszustandsklassifikation zur automatischen Fahrgasterfassung

Als weitere standortbezogene Dienste können Systeme zur automatischen Fahrgasterfassung gezählt werden, die nutzungsabhängige Fahrpreise berechnen (sogenannte Be-In-Be-Out-Systeme [Gründel 2005]). Die notwendigen technologischen Grundlagen wurden unter anderem im Rahmen des BMBF-geförderten Leitprojektes intermobil Region Dresden [Gründel et al. 2001] sowie im SAB-geförderten Projektes „Cool Public Transport Information“ (CPTI) [Partzsch et al. 2013b, Irmer et al. 2014] untersucht. Die mobile Sensorplattform wird in diesem Kontext Nutzermedium genannt und kann die Form eines Schlüsselanhängers oder einer Chipkarte besitzen.

Im Rahmen von CPTI wurden Klassifikatoren für Bewegungsmuster wie folgt diskutiert und genutzt [Irmer et al. 2014]:

1. Eine Vorrecherche lieferte das Ergebnis, dass der im Projekt eingesetzte Beschleunigungssensor deutlich weniger Energie zum Betrieb benötigt als der eingesetzte Chip für die Ortung im Sensornetz. Ein ständiger Betrieb des Funkchips ist daher unökonomisch. Es wurde diskutiert, einen Bewegungsmusterklassifikator auf Basis des Beschleunigungssensors zu nutzen, der Ruhe von Laufen unterscheiden kann. Dieser Ansatz ist prinzipiell möglich (siehe Kapitel 3.3 und 4.3), wurde im Laufe des Projekts zugunsten eines speziellen und damit noch energieeffizienteren funkbasierten Weckens (engl. wake-on-radio) verworfen.

2. Zur Optimierung des Ortungsprozesses in einem Fahrzeug hinsichtlich Zeit und Ressourcen wurde ein Verfahrensablauf entwickelt, der gezielt auf Klassifikatoren von Bewegungsmustern zurückgreift, u.a.
 - a. Zum Starten des Ortungsprozesses mittels Klassifikator „Anfahrtruckerennung“ für das Fahrzeug,
 - b. Optimierung der Datenübertragung durch Bewertung der Nutzermediumsbewegung mittels Klassifikator „Bewegungsmaßbestimmung“ auf dem Nutzermedium und
 - c. Zuordnung eines Nutzermediums zu einem Fahrzeug mittels Klassifikator Signalkorrelation.

6.2.1.1 Starten des Ortungsprozesses: Anfahrtruckerennung

Grundlage für das Starten des Ortungsprozesses ist das Türsignal, das angibt, ab wann die Türen geschlossen sind, und somit kein Fahrgastwechsel mehr stattfindet. Ab dem Zeitpunkt geschlossener Türen wird nach dem Anfahrtruck gesucht, um an der Haltestelle wartende Fahrgäste von im Fahrzeug mitfahrende Fahrgäste anhand der Beschleunigungsmuster unterscheiden zu können.

Für die Anfahrtruckerennung des Fahrzeugs wird der Übergang von Zustand „Stand“ zu Zustand „Fahrt“ detektiert. Neben den vorgestellten Möglichkeiten der Unterscheidung mittels Varianz (siehe Abschnitt 4.2.6) und FFT-Koeffizienten-Teilsummen (siehe Abschnitt 5.4.2) ist die Nachverfolgung des x -Signals auf einen deutlichen Anstieg hin möglich. Der in Abbildung 73 gezeigte Entscheidungsbaum verknüpft das Merkmal A-E-Differenz aus Abschnitt 3.4.3 mit dem Status der Türen eines Fahrzeugs, der entweder „offen“ (eine Tür ist geöffnet, im Normalfall an einem Halt) oder „geschlossen“ (alle Türen sind geschlossen) sein kann. Beim ersten Überschreiten des vorgegebenen Schwellwerts für die A-E-Differenz ist also von einem Anfahrtsvorgang auszugehen.

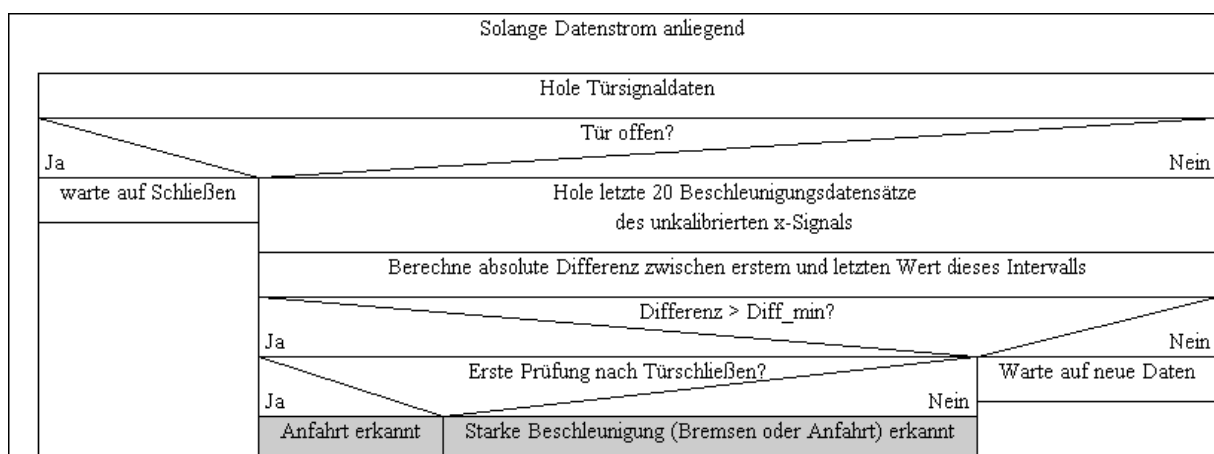


Abbildung 73: Entscheidungsbaum Anfahrtruckerennung

Die logische Verknüpfung des x -Signals (beispielhaft dargestellt in Abbildung 74, oben) mit dem Türsignal (Abbildung 74, Mitte) ist notwendig, da auf Grund der Differenzbildung (Abbildung 74, unten) nicht entschieden werden kann, ob es sich um den Anfang eines Anfahrtrucks oder das Ende eines Bremsvorganges handelt. Alle Überschreitungen des Schwellwertes nach einer „offen“-Phase sind Anfahrvorgänge.




Abbildung 74: Messbeispiel zur Anfahrtruckerkennung

6.2.1.2 Nutzermedium-Fahrzeug-Zuordnung

Aufbauend auf die Anfahrtruckerkennung des Fahrzeugs kann nun der Ortungsprozess weiter mit Hilfe von Bewegungsdaten unterstützt werden, siehe Irmer et al. (2014).

Ziel ist die energieeffiziente Zuordnung eines Nutzermediums zu einem Fahrzeug. Da ein Beschleunigungssensor verglichen mit anderen Ortungstechnologien wenig Energie benötigt, um Informationen über den Zustand zu sammeln, ist es sinnvoll, diese Informationen bestmöglich auszuwerten.

Wurde auf Seiten des Fahrzeugs ein Anfahren erkannt, werden die Nutzermedien aufgerufen, zu prüfen, ob sie sich in dem Zeitabschnitt ähnlich stark bewegt haben. Diese Entscheidung wird anhand des Merkmals der Spannweite getroffen. Bewegt es sich deutlich weniger als das Fahrzeug, kann es nach Anfahrt nicht mitbewegt worden sein (Zustand: „außerhalb“, „Be-Out“). Bewegt es

sich stärker als das Fahrzeug, muss eine andere Technologie genutzt werden, da vermutlich menschliche Bewegungsformen die Fahrzeugbewegungen überdecken (siehe Diskussion im Unterkapitel 4.5, Frage 1). Liegen Nutzermediums- und Fahrzeugdatenspannweite in einer gleichen Größenordnung, wird die Datenübertragung ausgelöst. Es kann mit Hilfe der Korrelation entschieden werden, ob sich das Nutzermedium wie das Fahrzeug bewegt hat und, ob sich das Medium in diesem Fahrzeug befindet (Zustand: „innen“, „Be-In“).

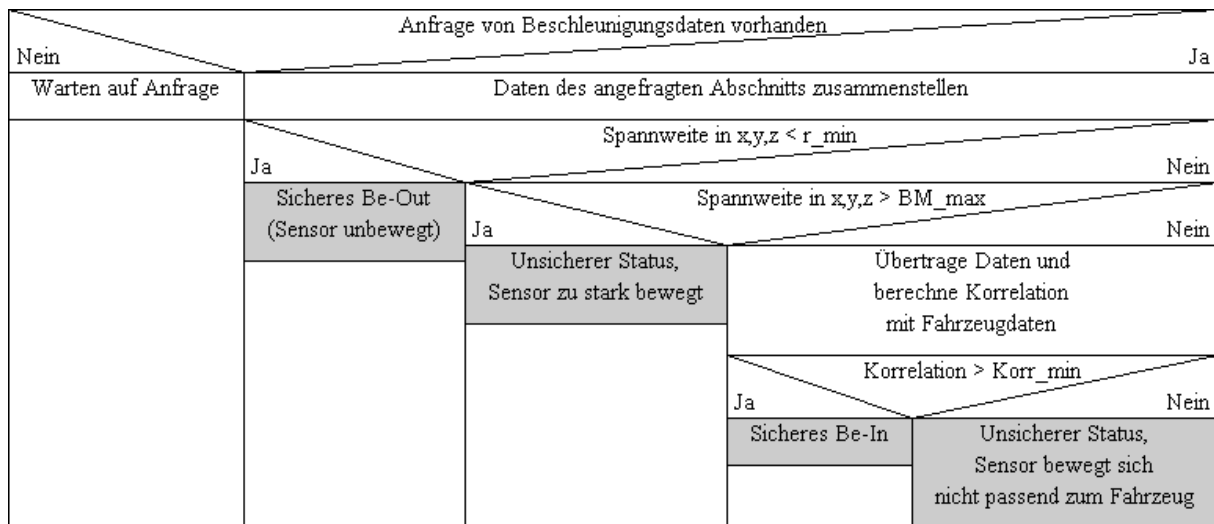


Abbildung 75: Ortungsalgorithmus in Anlehnung an CPTI (2013) und Irmer et al. (2014)

7 Zusammenfassung

In diesem Kapitel werden die Ergebnisse zusammengefasst und einer Methodenkritik unterzogen. Anwendungsempfehlungen bilden den Abschluss der Arbeit.

7.1 Zusammenfassung und Bewertung der Ergebnisse

Diese Arbeit befasst sich mit der Identifikation von Bewegungszuständen mittels Inertialsensorik – konkret Beschleunigungssignalen – für die Stützung von Navigationsfunktionen im ÖPV.

Dazu werden geeignete Messsysteme zur Erfassung von Beschleunigungen, die die Bewegungen von Fahrzeugen und Personen beschreiben, dargestellt. Dies sind die Dresdner Messstraßenbahn als Fahrzeugreferenz und eine Sensorplattform auf Basis des deRFnodes, die für die Erfassung von Fahrzeug- und Personenschwingungen verwendet wird.

Es werden die von den Messsystemen zu erfassenden Bewegungszustände von Fahrzeugen und Personen mit einem geschichteten Bewegungszustandsmodell aus Bewegungsmoduserkennung und Bewegungszustandserkennung in den einzelnen Modi beschrieben. In diesem Modell werden die verschiedenen in einer ÖPV-Umgebung zu betrachtenden Bewegungszustände und -modi definiert und miteinander verbunden.

Dieses Modell ist Grundlage für den in der Arbeit entwickelten und genutzten Algorithmus zur Bewegungszustandserkennung. Es werden drei Klassifikatortypen, der heuristische Entscheidungsbaum, die lineare und die quadratische Diskriminanzanalyse verwendet und jeder Klassifikatortyp mit und ohne eine nachgelagerte Filterung mittels Hidden Markov Model umgesetzt. Jeder Klassifikator benötigt Klassifikationsinformationen. Diese werden durch die statistische Analyse der gemessenen Bewegungssignale gewonnen.

Die erstellten Klassifikatoren werden mit dem in dieser Arbeit entwickelten Ansatz wahrscheinlichkeitsbasierter Güteschranken bewertet. Für die Trainingsdaten werden die Zustände mit einer über der geforderten Güteschranke liegenden Güte identifiziert. Die Generalisierungsfähigkeit ist jedoch von der gewählten Klassifikatorstruktur und von den zu Grunde liegenden Trainingsdaten abhängig.

In der Arbeit wird außer der Klassifikation von Bewegungssignalen deren Reproduktion im Labor diskutiert. Grundlage ist die Laborumgebung an der Professur „Informationstechnik für Verkehrssysteme“ der TU Dresden zur Wiedergabe von Ortungs- und Kommunikationssignalen zum originalgetreuen Ersatz von realen Messfahrten durch laborgestützte Versuche. Prinzipiell lassen sich

Schwingungssignale derart im Labor erzeugen, dass diese, wenn sie wieder aufgenommen werden, in gleicher Weise wie ein Originalsignal klassifiziert werden. Auf Grund der Übertragungseigenschaften der beteiligten Systeme ist eine gezielte Merkmalsauswahl nötig. Dieser Ansatz kann zum Test standortbezogener Dienste verwendet werden. Exemplarisch diskutiert werden das logische Map Matching für Navigationsaufgaben, sowie Möglichkeiten der automatischen Fahrgasterfassung in ÖPV-Fahrzeugen. Letztere Anwendung kann genauso zur Navigation der Fahrgäste verwendet werden und ist für die nutzungsabhängige Fahrpreisberechnung notwendig.

7.2 Methodenkritik

Die vorliegenden Ergebnisse haben exemplarischen Charakter. Sie müssen bezüglich ihrer Datenherkunft, der gewählten Analyseansätze und der gewählten Verfahrensweise diskutiert werden.

7.2.1 Datenherkunft

In die Betrachtungen dieser Arbeit gingen zwei charakteristische Fahrzeugtypen (Bus, Straßenbahn) ein. Die Erkenntnisse für diese Fahrzeugtypen sind erweiterbar um andere Fahrzeuge (andere Busse oder Straßenbahnen) oder andere Modi (Eisenbahn, Fähre, Standseilbahn). Die Untersuchungen sind nicht auf das Netz der DVB beschränkt und auch in anderen ÖPV-Netzen anhand der aufgezeigten Methode möglich. Zur Generierung der Messdaten für die Personenbewegungszustände wurden willkürlich weibliche Testpersonen verwendet. Obwohl unter anderem das Geschlecht einen Einfluss auf den Bewegungsablauf im Detail hat (u.a. diskutiert von Krauß (2006)), ist bei der Unterscheidung der in dieser Arbeit verwendeten grundsätzlichen Bewegungsformen von einer Übertragbarkeit auf andere Testpersonen unabhängig vom Geschlecht auszugehen.

7.2.2 Analysedatensätze

Die prinzipielle Nutzbarkeit der Methode zur Identifizierung von Bewegungszuständen wurde anhand von exemplarischen Messfahrten gezeigt. Es ist sinnvoll, diese Datengrundlage je nach betrachteter Fragestellung zu erweitern. Eine größere Lerngrundlage bietet für statistische Verfahren eine geeignetere Entscheidungsgrundlage mit geringerer Gefahr der Überanpassung auf zu geringe Varianzen in den Lernmerkmalen. Genauso bietet eine größere Testgrundlage eine größere Sicherheit über die Generalisierbarkeit der gefundenen Aussagen.

7.2.3 Eignung der Verfahrensweise

Die gewählte Verfahrensweise zur Identifikation von Bewegungszuständen auf Basis von Beschleunigungssignalen umfasst zum einen eine geschichtete Zustandsmodellierung sowie ein Training eines Klassifikators, der anschließend hinsichtlich seiner Allgemeingültigkeit getestet werden kann.

Auf Grund der physikalischen – achsenbezogenen – Entstehungsweise der betrachteten Bewegungssignale, und auf Grund der Tatsache, dass eine Reproduktion im Labor immer achsenbezogen erfolgt, ist die Zerlegung der Zustandsbetrachtung anhand der Bewegungsachsen sinnvoll.

Die beiden gewählten Klassifikatoransätze heuristischer Entscheidungsbaum und Diskriminanzanalyse zeigen die prinzipielle Funktionsweise des Vorgehens. Die Ergebnisse sind als exemplarische Klassifikatorleistungen zu diskutieren und können prinzipiell durch diejenigen Ergebnisse beliebiger anderer Klassifikatoren ausgetauscht werden.

Es zeigte sich, dass der heuristische Entscheidungsbaum bei einer überschaubaren Menge an unabhängigen Zuständen und Merkmalen sinnvoll ist, da hier durch die menschliche Abstraktionsfähigkeit bei kleinen Datengrundlagen eine gute Generalisierbarkeit möglich ist.

Statistische Ansätze, wie die Diskriminanzanalyse, haben bei großer Anzahl möglicher Zustände und unabhängiger Merkmale Vorteile. Die Bedingung für eine gute Generalisierbarkeit ist eine aussagekräftige Datengrundlage mit korrekter Verteilung der Merkmale, wie sie oft nur für große Datenmengen erreichbar ist.

Da für die vorliegende Klassifikationsaufgabe keine vergleichbaren Ergebnisse vorlagen, wurden im Rahmen dieser Arbeit Qualitätsschranken zur Bewertung der Klassifikatorleistung entwickelt (siehe Abschnitt 3.4.3). Auf Grund ihrer stochastischen Begründbarkeit sind diese Schranken allgemeingültig anwendbar. Künftige Arbeiten in diesem Kontext können nun an den in dieser Arbeit erreichten Ergebnissen und an den entwickelten Qualitätskenngrößen hinsichtlich ihrer Korrektheit gemessen werden.

7.3 Anwendungsempfehlungen

Wie im Kapitel 6 gezeigt, gibt es relevante Anwendungsfälle für auf Basis von Beschleunigungssignalen identifizierte Bewegungszustände.

Der dargestellte Fall der Unterstützung von ÖPV-Navigationssystemen ist immer dort relevant, wo die üblicherweise verwendeten Satellitennavigationssysteme an ihre Grenzen stoßen. Dies trifft in besonderem Maße auf U-Bahn-Systeme zu. Für ein logisches Map Matching, siehe Unterkapitel

2.7 und 6.1, ist die Wahl robuster Merkmale sowie eine logische Zustandsüberwachung, die mit Überlagerungen durch Personenbewegung umgehen kann, notwendig. Beispielsweise könnte logisch überprüft werden, ob eine Person aufgestanden ist, weil eine Haltestelle erreicht worden ist, oder ob dies in der Mitte eines Fahrabschnittes passierte. Die geeignete Merkmalswahl und die Zustandsüberwachung sind wesentliche Forschungsbausteine für eine solche Navigation auf Basis von Beschleunigungssignalen. Darüber hinaus ist eine gut entworfene Trainingsdatengrundlage (Messplattformdesign, Messplattformposition, Datenprüfung und -vorverarbeitung) essentiell.

Für die ebenfalls im Kapitel 6 diskutierte Fahrgasterfassung kann der Beschleunigungssensor eine energieeffiziente Informationsquelle über den Bewegungszustand des Fahrzeugs und des Fahrgastes sein. Bei geeigneter Fahrzeugreferenz ist ein Rückschluss darauf möglich, dass der Fahrgast sich in einem Fahrzeug befindet. Für die geeignete Positionierung des Referenzsensors im Fahrzeug ist darauf zu achten, dass Störsignale vom Fahrzeug (starke Antriebsaggregat-Vibrationen, Karosserie-Vibrationen), die durch Dämpfungselemente nicht oder gedämpft beim Fahrgast ankommen, auch am Sensor nicht anliegen.

Diese Arbeit zeigt damit einen vielversprechenden Weg auf, Beschleunigungsdaten zur Identifikation von Bewegungszuständen und damit zur Stützung von Navigationsfunktionen zu nutzen. Es wurde gezeigt, dass eine manuell erzeugte Klassifikatorstruktur mit wenigen Daten in der Lage ist, Bewegungsmodi und -zustände effektiv zu trennen. Die Effizienz wurde mittels eines wahrscheinlichkeitsbasierten Ansatzes nachgewiesen. Prinzipiell ist dieses Vorgehen für weitere Anwendungen empfehlenswert, wenn geringe Datenmengen vorhanden sind und damit die Gefahr einer Überanpassung besteht.

Glossar

Bewegung

Ortsveränderung im Raum

Bewegungsmodus

Art der Ortsveränderung (Wahl des Transportgefäßes, z. B. Fortbewegung zu Fuß oder mittels Fahrzeug); im Rahmen dieser Arbeit gleichgesetzt mit \rightarrow *Verkehrsmittel*

Bewegungszustand

Detaillierte Bewegungsart während der Nutzung eines \rightarrow *Bewegungsmodus* (Rennen vs. gehen; Kurvenfahrt vs. Geradeausfahrt etc.)

Bipedie

Oberbegriff für allgemeine zweibeinige \rightarrow *Personenbewegung*, die auf Fortbewegung abzielt; verschiedene Arten möglich: \rightarrow *Gehen*, \rightarrow *Laufen*

Fahrzeugbewegung

\rightarrow *Bewegung* des Fahrzeugs

Gehen

Langsame \rightarrow *Personenbewegung* (\rightarrow *Bipedie*), bei der zu jedem Zeitpunkt mindestens ein Bein den Boden berührt

Laufen

Schnelle \rightarrow *Personenbewegung* (\rightarrow *Bipedie*), bei der eine Flugphase existiert, zu der keines der Beine den Boden berührt

Personenbewegung

\rightarrow *Bewegung* einer Person, bei Fortbewegung verbunden mit \rightarrow *Bipedie*

Resultierende Personenbewegung

\rightarrow *Bewegung* einer Person, die ein(bewegtes) Fahrzeug nutzt

Resultierende *Smartphone*-Bewegung

\rightarrow *Bewegung* eines *Smartphone*, das sich in einem (bewegten) Fahrzeug befindet und gegebenenfalls durch \rightarrow *Nutzerbewegungen* beeinflusst wird

Smartphone-Bewegung

→*Bewegung* eines Smartphones

Verkehr

Zusammenfassung von →*Bewegungen* mehrerer Objekte in einem (Verkehrs-)System

Verkehrsmittel

Im weiteren Sinn nach Ammoser et al. (2006): Gesamtheit der stationären bzw. mobilen sowie materiellen und immateriellen Arbeits- und Produktionsmittel, die die → *Bewegung* von Gütern, Personen und Nachrichten ermöglichen; im Kontext dieser Arbeit gleichgesetzt mit →*Bewegungsmodus* (konkret im motorisierten Fall mit Fahrzeug)

Verkehrsmittelwahl

Entscheidung für einen →*Bewegungsmodus*

Literaturverzeichnis

- Ahrens et al. 2009** AHRENS, Gerd-Axel; LIEßKE, Frank; WITTEW, Rico; HUBRICH, Stefan: *Sonderauswertung zur Verkehrserhebung "Mobilität in Städten – SrV 2008" SrV-Stadtgruppe: Oberzentren, 500.000 EW u. mehr (o. Berlin), Topografie: flach*. Technische Universität Dresden, 2009.
- Alanezi et al. 2013** ALANEZI, Khaled und MISHRA, Shivakant: *Impact of Smartphone Position on Sensor Values and Context Discovery*. Techreport, Department of Computer Science, University of Colorado Boulder, 2013.
- Ammoser et al. 2006** AMMOSER, Hendrik und HOPPE, Mirko: *Glossar Verkehrswesen und Verkehrswissenschaften. Definitionen und Erläuterungen zu Begriffen des Transport- und Nachrichtenwesens*. Diskussionsbeiträge aus dem Institut für Wirtschaft und Verkehr, Nr. 2, Technische Universität Dresden, 2006.
- Bergmann et al. 2003** BERGMANN, Fridhelm, GERHARD, Hans-Joachim und FROHBERG, Wolfgang (Hrsg.): *Taschenbuch der Telekommunikation*. 2. Aufl. Leipzig: Fachbuchverlag Leipzig, 2003.
- Berthold et al. 2003** BERTHOLD, Michael und HAND, David J. (Hrsg.): *Intelligent Data Analysis – An Introduction*. 2. Aufl., Berlin/Heidelberg: Springer, 2003.
- Bocksch et al. 2013** BOCKSCH, Marcus; SEITZ, Jochen; und JAHN, Jasper: Pedestrian Activity Classification to Improve Human Tracking and Localization. In: *IPIN 2013*, Montbéliard, 2013.
- Bosch 2008** BOSCH Sensortec GmbH: *BMA 150 Digital, triaxial acceleration sensor Data sheet*. BST-BMA150-DS000-06, Oktober 2008.
- Bosch 2014** BOSCH Sensortec GmbH: *Weltweit führender Anbieter - Vier Milliarden MEMS-Sensoren von Bosch - Schlüsseltechnologie für das Internet der Dinge*. Presse-Information Nr. 8617, 24. Juni 2014.
- Bosina 2012** BOSINA, Ernst: *Bewegungscharakteristika des Fußgängerverkehrs unter besonderer Berücksichtigung der Beschleunigung*. Masterarbeit. Universität für Bodenkultur Wien, 2012.
- Braess et al. 2007** BRAESS, Hans-Hermann und SEIFFERT, Ulrich (Hrsg.): *Vieweg Handbuch Kraftfahrzeugtechnik*. Wiesbaden: Vieweg, 2007.
- Breiman et al. 1984** BREIMAN, L., FRIEDMAN, J.; OLSHEN, R. und STONE, C.: *Classification and Regression Trees*. Boca Raton, FL: CRC Press, 1984.
- Bronstein et al. 2001** BRONSTEIN, I.N.; SEMENDJAEV, K.A.; MUSIOL, G. und MÜHLIG, H.: *Taschenbuch der Mathematik*. 5. Aufl. Thun: Harri Deutsch, 2001.

- Cavagna et al. 1997** CAVAGNA, G.A.; MANTOVANI, M.; WILLEMS, P.A. und MUSCH, G.: The resonant step frequency in human running. In: *Pflügers Arch – Eur J Physiol*, Nr. 434, S. 678–684, 1997.
- Cherkassky et al. 2007** CHERKASSKY, Vladimir; MULIER, Filip M.: *Learning from Data: Concept, Theory, and Methods*. New York: Wiley, 2007.
- Coermann 1962** COERMANN, Rolf-R.: *The Mechanical Impedance of the Human Body in Sitting and Standing Position at Low Frequencies*. In: *Human Factors*. Vol 4. S. 227-253, 1962.
- Colibris 2015** COLIBRIS: *Advantage of capacitive MEMS accelerometer vs other technologies*. Foliensatz, 05. Mai 2015.
- Collin 2006** COLLIN, Jussi: *Investigations of Self-Contained Sensors for Personal Navigation*. Dissertation. Tampere University of Technology. Publication 619, 2006.
- Dai et al. 2010** DAI, Jiangpeng; BAI, Xiaole; YANG, Zhimin; SHEN, Zhaohui und XUAN, Dong: Mobile phone-based pervasive fall detection. In: *Pers Ubiquit Comput* 14, pp. 633-643, Springer 2010.
- DAkkS 2010** Deutsche Akkreditierungsstelle GmbH: *Richtlinie DAkkS-DKD-R 3-1 Kalibrierung von Beschleunigungsmessgeräten nach dem Vergleichsverfahren, Blatt 3 Sinus- und Multisinus-Anregung*. 1. Neuaufl. 2010.
- Dandy et al. 1984** DANDY, Graeme Clyde und MCBEAN, Edward Arthur: Variability of individual travel time components. In: *J. of Transp. Eng.*. Vol. 110, No.3, 1984.
- de 2016** dresden elektronik: deRFnode. <https://www.dresden-elektronik.de/funktechnik/products/boards-and-kits/development-boards/derfnode/description/> (zuletzt abgerufen am 23.05.2016).
- Demtröder 2008** DEMTRÖDER, Wolfgang: *Experimentalphysik 1 – Mechanik und Wärme*. 5. Aufl., Berlin: Springer Verlag, 2008.
- DIN 1319-3** Deutsches Institut für Normung e.V.: *Grundlagen der Messtechnik - Teil 3: Auswertung von Messungen einer einzelnen Meßgröße, Meßunsicherheit*. Berlin: Beuth 1996.
- DIN EN 62008** Deutsches Institut für Normung e.V.: *Leistungseigenschaften und Kalibrierverhalten für digitale Datenerfassungssysteme und entsprechende Software (IEC 62008:2005)*. Berlin: Beuth 2005.
- Duda et al. 2001** DUDA, Richard O.; HART, Peter E.; STORK, David G.: *Pattern Classification*. 2. Aufl.. New York: Wiley, 2001.
- Dürschmidt et al. 2012** DÜRRSCHMIDT, Gunther; BEITELSCHMIDT, Michael; PARTZSCH, Ina und MICHLER, Oliver: Verwendung von fahrwegspezifischen Beschleunigungsmustern zur Fahrzeugortung von Straßenbahnen: In: *Rad-Schiene*, Dresden, 2012.

- Dürschmidt 2014** DÜRRSCHMIDT, Gunther: Bereitstellung von Messstraßenbahndaten (Beschleunigungsmessung, GPS-Daten) aus dem Archiv der Messstraßenbahn für 14.1.2014.
- Eckey et al. 2002** ECKEY, Hans-Friedrich; KOSFELD, Reinhold und RENGERS, Martina: *Multivariate Statistik – Grundlagen – Methoden – Beispiele*. 1. Aufl.. Wiesbaden: Gabler, 2002.
- Eichler 2004** EICHLER, Jürgen: *Physik – Grundlagen für das Ingenieurstudium – kurz und prägnant*. Wiesbaden: Vieweg, 2004.
- Eltzschig 2014** Persönliche Kommunikation zum Entwurf eines Laborschwingungsgenerators. 2014.
- Euler 1752** EULER, Leonard: Decouverte d'un nouveau principe de Mecanique. In: *Mémoires de l'académie des sciences de Berlin*. Nr. 6, 1752, S. 185-217
- Figo et al. 2010** FIGO, Davide; DINIZ, Pedro C.; FERREIRA, Diogo R.; CARDOSO, João M.P.: Preprocessing techniques for context recognition from accelerometer data. In: *Pers. Ubiquit Comput* (2010), Vol. 14, S. 645-662.
- Fink 2003** FINK, Gernot A.: *Mustererkennung mit Markov-Modellen – Theorie – Praxis – Anwendungsgebiete*. 1. Aufl.. Wiesbaden: B.G. Teubner Verlag, 2003.
- Fisz 1958** FISZ, Marek: Wahrscheinlichkeitsrechnung und Mathematische Statistik. Berlin: VEB Dt. Verlag d. Wissenschaften, 1958.
- Fisher 1936** FISHER, Ronald Aylmer: The use of multiple measurements in taxonomy problems. In: *Annals of Eugenics* Vol. 7, 1936, S.179-188.
- Fraden 2010** FRADEN, Jacob: *Handbook of Modern Sensors*. Dordrecht: Springer, 2010.
- Frank et al. 2010** FRANK, Jordan; MANNOR, Shie und PRECUP, Doina: Activity and Gait Recognition with Time-Delay Embeddings. In: *Proc. 24th AAAI*, Atlanta, Georgia, 2010.
- Franke 1969** FRANKE, Hermann (Hrsg.): Lexikon der Physik, Bd. 3., 3. Aufl.. Stuttgart: Franckh'sche Verlagshandlung, W. Keller & Co., 1969.
- Gerlach et al. 2006** GERLACH, Gerald und DÖTZEL, Wolfram: *Einführung in die Mikrosystemtechnik – Ein Kursbuch für Studierende*. München/Wien: Fachbuchverlag Leipzig, 2006.
- Gerlach et al. 2009** GERLACH, Katrin und RAHMIG, Christian: Multi-Hypothesis Based Map-Matching Algorithm for Precise Train Positioning. In: *12th Inter. Conf. on Information Fusion*. Seattle, 6.-9.Juli 2009.
- Ghahramani 2001** GHAHRAMANI, Zoubin: An Introduction to Markov Models and Bayesian Networks. In: *Int. J. Pattern Recognition and Artificial Intelligence*. 15 (1):9-42, 2001
- Gierisch et al. 2015** GIERISCH, Florian; MICHLER, Oliver; ELTZISCHIG, Bert und PARTZSCH, Ina: Kalibrierung eines vertikalen Beschleunigungsgenerators

- innerhalb der NI-basierten in-the-loop-Testlaborumgebung für Location Based Services. . In: *NI VIP 2015*, Fürstenfeldbruck, 2015.
- Groves 2007** GROVES, Paul D.: *Principles of GNSS, Inertial, and Multisensor Integrated Navigation Systems*. Norwood: Artech House, 2007.
- Gründel et al. 2001** GRÜNDEL, Torsten; LORENZ, Helge und RITSCHEL, M.: Ein Systemkonzept für das elektronische Fahrgeldmanagement in der Region Dresden/Oberelbe. In: *Proceedings 18. VWT*, Dresden, 2001.
- Gründel 2005** GRÜNDEL, Torsten: *Ein Beitrag zur automatisierten Berechnung von Leistungsparametern des ÖPNV mittels Daten aus elektronischen Fahrgeldmanagementsystemen*. Dissertation. Technische Universität Dresden, 2005.
- Gusenbauer et al. 2010** GUSENBAUER, Dominik; ISERT, Carsten und KRÖSCHE, Jens: Self-Contained Indoor Positioning on Off-The-Shelf Mobile Devices. In: *IPIN 2010*, Zürich, 15-17 September, 2010.
- Hall 1999** HALL, Mark A.: *Correlation-based Feature Selection for Machine Learning*. Dissertation. The University of Waikato, 1999.
- Han et al. 2006** HAN, Jiawei und KAMBER, Micheline: *Data Mining: Concepts and Techniques*. Second Edition. San Francisco: Morgan Kaufmann, 2006.
- Harrison 2004** HARRISON, Matthew: *Vehicle Refinement: Controlling Noise and Vibration in Road Vehicles*. Burlington: Butterworth-Heinemann, 2004.
- Harter et al. 2009** HARTER, Matthias; BEITELSCHMIDT, Michael; STRIEGLER, Gerd und SAUERMAN, Ingolf: Die Dresdner Messstraßenbahn – Konzept, Architektur, Komponenten. In: *ETR*, Vol. 12, 2009.
- Heidrich et al. 2013** HEIDRICH, Andre; WOLF, Benjamin und MICHLER, Oliver: Multisensorbasierte Fahrzeugortungssysteme im Labor validieren. In: *VIP 2013*, München, 23.-24. 10.2013.
- Heirich et al. 2011** HEIRICH, Oliver; LEHNER, Andreas; ROBERTSON, Patrick und STRANG, Thomas: Measurement and Analysis of Train Motion and Railway Track Characteristics with Inertial Sensors. In: *Proc. 14th Int. IEEE Conf. on ITS*, Washington, October 5-7, 2011.
- Hochstädter 1991** HOCHSTÄDTER, Dieter: *Statistische Methodenlehre – Ein Lehrbuch für Wirtschafts- und Sozialwissenschaftler*. Frankfurt am Main: Harri Deutsch, 1991.
- Hoffmann 1998** HOFFMANN, Rüdiger: *Signalanalyse und -erkennung – Eine Einführung für Informationstechniker*. Berlin: Springer Verlag, 1998.
- Hua et al. 2015** HUA, Jingyu; SHEN, Zjenyu; ZHONG, Sheng: We Can Track You If You Take the Metro: Tracking Metro Riders Using Accelerometers on Smartphones. In: *CoRR*. arXiv:1505.05958 [cs.CR], 2015.

- Irmer et al. 2014** IRMER, Stefan u.a.: *Sachbericht Cool Public Transport Information – CPTI. Berichtszeitraum 15.08.2011-30.06.2014, Zuwendungsempfänger Fraunhofer-Gesellschaft e.V.*. Dresden: Fraunhofer IVI, 2014.
- Iwnicki 2006** Iwnicki, Simon: *Handbook of Railway Vehicle Dynamics*. Hoboken, CRC Press, 2006.
- Jain et al. 2000** JAIN, Anil K.; DUIN, Robert P.W. und MAO, Jienchang: Statistical Pattern Recognition: A Review. In: *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 22, No1. IEEE: 2000.
- JCGM 2008** Joint Committee for Guides in Metrology (Hrsg.): *Evaluation of measurement data – Guide to the expression of uncertainty*. BIPM, 2008.
- Johnson et al. 2011** JOHNSON, Derick A. und TRIVEDI, Mohan M.: Driving Style Recognition Using a Smartphone as a Sensor Platform. In: *Proc. 14th Int. IEEE Conf. on ITS*, Washington, October 5-7, 2011.
- Junghans 2009** JUNGHANS, Marek: *Ein Beitrag zur Qualifizierung von Verkehrsdaten mit Bayesischen Netzen*. Technische Universität Dresden, 2009. – Dissertation
- Karaduman et al. 2013** KARADUMAN, O.; EREN, H.; Kurum, H.; CELENK, M.: An Effective Variable Selection Algorithm for Aggressive/Calm Driving Detection via CAN Bus. In: *Proc. ICCVE*, 2013.
- Kohla 2013** KOHLA, Birgit: *Erkennung von Wegetappen und Verkehrsmitteln für Mobilitätshebungen mit mobilen Erhebungsgeräten*. Dissertation, Universität für Bodenkultur Wien, 2013.
- Krauß 2006** KRAUß, Inga: *Frauenspezifische Laufschubkonzeption – eine Betrachtung aus klinischer, biomechanischer und anthropometrischer Sicht*. Dissertation, Eberhard-Karls-Universität Tübingen, 2006.
- Krygsman et al. 2004** KRYGSMAN, Stephan, DIJST, Martin und ARENTZE, Theo: Multimodal public transport: an analysis of travel time elements and the interconnectivity ratio. In: *Transport Policy*. Vol. 11, S. 265-275, Elsevier: 2004.
- Kwapisz et al. 2010** KWAPISZ, Jennifer; WEISS, Gary M. und MOORE, Samuel A.: Activity Recognition using Cell Phone Accelerometers. In: *ACM SIGKDD Explorations Newsletter*, Vol.12, Issue 2, ACM, New York, 2010.
- Langrock et al. 1979** LANGROCK, P. und JAHN, W.: *Einführung in die Theorie der Markovschen Ketten und ihre Anwendungen*. Mathematisch-Naturwissenschaftliche Bibliothek, Bd. 49. Leipzig: B.G. Teubner, 1979.
- Lee et al. 2011** LEE, Myong-Woo; KHAN, Adil Mehmood und KIM, Tae-Seong: A single tri-axial accelerometer-based real-time personal life log system capable of human activity recognition and exercise information generation. In: *Pers Ubiquit Comput.* Vol. 15, S. 887 – 898, 2011.

- Lester et al. 2005** LESTER, Jonathan; CHOUDHOURY, Tanzeem, KERN, Nicky; BORRIELLO, Gaetano und HANNAFORD, Blake: A Hybrid Discriminative/Generative Approach for Modeling Human Activities. In: *IJCAI'05*, S. 766-772. San Francisco: Morgan Kaufman, 2005.
- Lester et al. 2006** LESTER, Jonathan; CHOUDHOURY, Tanzeem und BORRIELLO, Gaetano: A Practical Approach to Recognizing Physical Activities. In: KP. Fishkin et al. (Hrsg.): *PERVASIVE 2006, LNCS 3968*, pp. 1-16, 2006.
- Lin et al. 2003** LIN, Jessica; KEOGH, Eamonn; LEONARDI, Stefano und CHIU, Bill: A symbolic representation of time series, with implications for streaming algorithms. In: *Proc. 8th ACM SIGMOD DMKD*, San Diego, 13. Juni 2003.
- Malsch et al. 2007** MALSCH, Annette und HORNBERG, Claudia (Federführung): Infraschall und tieffrequenter Schall – ein Thema für den umweltbezogenen Gesundheitsschutz in Deutschland? Mitteilung der Kommission „Methoden und Qualitätssicherung in der Umweltmedizin“. In: *Bundesgesundheitsbl – Gesundheitsforsch – Gesundheitsschutz* 12, 2007, No. 50. S. 1582-1589.
- Mamar et al. 2008** MAMAR, Zahra Hamou; CHAINAIS, Pierre; AUSSEM, Alex: Combining learning methods and time-scale analysis for defect diagnosis of a tramway guiding system. In: *Proc. 18th Mediterranean Conf. on Control and Automation*, Ajaccio, France, June 25-27, 2008.
- Mannini et al. 2010** MANNINI, Andrea und SABATINI, Angelo Maria: Machine Learning Methods for Classifying Human Physical Activity from On-Body Accelerometers. In: *Sensors 2010*, Vol. 10, pp. 1154-1175.
- Mansfeld 2004** MANSFELD, Werner: *Satellitenortung und Navigation – Grundlagen und Anwendung globaler Satellitennavigationssysteme*. 2. Aufl., Wiesbaden: Vieweg, 2004.
- Mathie et al. 2004** MATHIE, Merryn J.; CELLER, Branko G.; LOVELL, Nigel H.; COSTER, Adelle C. F.: Classifications of basic daily movements using a triaxial accelerometer. In: *Medical & Biological Engineering & Computing 2004*, Vol. 42, p. 679-687.
- McConnell et al. 2008** MCCONNEL, Kenneth G.; VAROTO, Paulo S.: *Vibration Testing – Theory and Practice*. 2. Aufl., Hoboken: Wiley & Sons, 2008.
- Merziger et al. 2001** MERZIGER, Gehrhard, MÜHLBACH, Günter; WILLE, Detlef; WIRTH, Thomas: *Formeln + Hilfen zur Höheren Mathematik*. 4. Aufl., Hannover: Binomi, 2001.
- Michler et al. 2013** MICHLER, Oliver; RICHTER, Robert und FÖRSTER, Georg: Field and lab test results of vehicle positioning systems in weak GNSS signal environments using a multi-channel signal generator. In: *IGNSS 2013*, Outrigger Gold Coast, 2013.

- Michler et al. 2014** MICHLER, Oliver, RICHTER, Robert, FÖRSTER, Georg und PARTZSCH, Ina: Multisensorbasierte modulare Fahrzeugumfeldsimulation für vernetzte Ortungs- und Navigationssysteme: Potentiale, Grenzen sowie Feldtesterfahrungen einer verkehrsträgerübergreifenden Demonstrations- und Forschungsplattform. In: *POSNAV-ITS 2014*, Berlin, 2014.
- Mitschke 1962** Mitschke, Manfred: *Deutsche Kraftfahrtforschung und Straßenverkehrstechnik, Heft 157: Beitrag zur Untersuchung der Fahrzeugschwingungen (Theorie und Versuch)*. VDI-Verlag, Düsseldorf, 1962.
- Mitschke 1997** MITSCHKE, Manfred: *Dynamik der Kraftfahrzeuge. Band B: Schwingungen*. 3. Aufl.. Berlin, Heidelberg: Springer, 1997.
- Mizell 2003** MIZELL, David: Using Gravity to Estimate Accelerometer Orientation. In: *Proc. ISWC'03*, 2003.
- Newton 1687** NEWTON, Isaac: *Philosophiæ Naturalis Principia Mathematica*, London: Royal Society, 1687.
- NI 2015** National Instruments: *Benefits of Delta-Sigma Analog-to-Digital Conversion*. White Paper, Online-Version. <http://www.ni.com/white-paper/11342/en/> (abgerufen am 13.10.2015)
- Niemann 2003** NIEMANN, Heinrich: *Klassifikation von Mustern*. 2. Aufl.. Online-Version. <http://www5.cs.fau.de/fileadmin/Persons/NiemannHeinrich/klassifikation-von-mustern/m00links.html> (abgerufen am 2.10.2014)
- Parlak et al. 2012** PARLAK, Siddika; JARIYASUNANT, Jerald und SENGUPTA, Raja: Using Smartphones to Perform Transportation Mode Determination at the Trip Level. In: *TRB 2012 Annual Meeting*. 2012.
- Partzsch et al. 2011** PARTZSCH, Ina; MICHLER, Oliver; FÖRSTER, Georg und DÜRRSCHMIDT, Gunther: Multisensorielle Ansätze für gleisselektive Ortung in innerstädtischen bebauten Gebieten. In: *POSNAV-ITS 2011*, Darmstadt 2011.
- Partzsch et al. 2012** PARTZSCH, Ina; DÜRRSCHMIDT, Gunther und MICHLER, Oliver; FÖRSTER, Georg: Positioning in Real-Time Public Transport Navigation: Comparison of Vehicle-Based and Smartphone-Generated Acceleration Data to Determine Motion States of Passengers. In: *6th Int. Symp. „Networks for Mobility“*, Stuttgart, 2012.
- Partzsch et al. 2013a** PARTZSCH, Ina; KLIPPHAHN, Samuel; DÜRRSCHMIDT, Gunther und MICHLER, Oliver: New Approaches for Locating Railways Using Accelerometers, Vibration Sensors and Microphones. In: *ENC 2013*, Wien, 2013.

- Partzsch et al. 2013b** PARTZSCH, Ina und MICHLER, Oliver: Smartphone-generated Motion States for Passenger Localisation: Influence of Smartphone Position on Motion State Estimation. In: *mobil.TUM 2013*, München, 2013.
- Partzsch et al. 2013c** PARTZSCH, Ina; MICHLER, Oliver und FÖRSTER, Georg: Beschreibung eines Mehrkörpersystem-Modells zur Identifikation und Bewertung von Bewegungszuständen für die Lokalisierung von Fahrzeugen und Passagieren. In: *POSSNAV-ITS 2013*, Berlin, 2013.
- Partzsch et al. 2014a** PARTZSCH, Ina; FÖRSTER, Georg; RICHTER, Robert und MICHLER, Oliver: In-the-loop Testing of Location Based Services and Navigational Applications in a Laboratory Environment. In: *CERGA 2014*, Dresden, 2014.
- Partzsch et al. 2014b** PARTZSCH, Ina; FÖRSTER, Georg und MICHLER, Oliver: Record and Playback of Inertial Signals for In-the-Loop Testing of Location Based Services. In: *ISS 2014*, Karlsruhe, 2014.
- Partzsch et al. 2014c** PARTZSCH, Ina; FÖRSTER, Georg; ELTZSCHIG, Bert; MICHLER, Oliver: Record und Playback von Inertialsignalen mittels integrierter NI-basierter in-the-loop Testlaborumgebung für Location Based Service. In: *NI VIP 2014*, Fürstenfeldbruck, 2014.
- Partzsch et al. 2016** Persönliche Kommunikation mit Johannes und Lothar Partzsch am 7.2.2016
- Paulus et al. 1998** PAULUS, Dietrich W.R. und HORNEGGER, Joachim; *Applied Pattern Recognition*. 2nd Ed.. Wiesbaden: Vieweg, 1998.
- Piersol et al. 2010** PIERSOL, Allan G. und PAEZ, Thomas L.: *Harris' Shock and Vibration Handbook*. 6. Aufl. New York, McGraw-Hill, 2010.
- Popp et al. 1993** POPP, Karl und SCHIEHLEN, Werner: *Fahrzeugdynamik – Eine Einführung in die Dynamik des Systems Fahrzeug – Fahrweg*. Stuttgart: B.G. Teubner, 1993.
- Preece et al. 2009** PREECE, Stephen J.; GOULERMAS, John Yannis; KENNEY, Laurence P.J. und HOWARD, David: A Comparison of Feature Extraction Methods for the Classification of Dynamic Activities From Accelerometer Data. In: *IEEE Transactions on Biomedical Engineering*, Vol. 56, No. 3, March 2009.
- Pütz 2012** PÜTZ, Ralph: *Einführung in die Linienbustechnik*. Meerbusch: Alba, 2012.
- Quddus et al. 2007** Quddus, M. A.; Ochieng, W. Y. and Noland, R. B.: Current map-matching algorithms for transport applications: State-of-the-art and future research directions. In: *Transportation Research Part C, Emerging Technologies*, Vol. 15, Issue 5, S. 312-328, 2007.
- Rasmussen 1982** RASMUSSEN, Gunnar: *Human body vibration exposure and its measurement*. Technical review, Ausgabe 1, S. 3-31, Naerum: Bruel & Kjaer, 1982.
- Recknagel 1979** RECKNAGEL, Alfred: *Physik – Schwingungen und Wellen, Wärmelehre*. 11. Aufl.. Berlin, Verlag Technik, 1990.

- Reddy et al. 2010** REDDY, Sasank; MUN, Min; BURKE, Jeff; ESTRIN, Deborah; HANSEN, Mark und SRIVASTAVA, Mani: Using Mobile Phones to Determine Transportation Modes. In: *ACM Transactions on Sensor Networks*, Vol. 6, No.2, Article 13, 2010.
- Richter et al. 2013** RICHTER, Robert; WOLF, Benjamin und MICHLER, Oliver: Evaluation of GNSS RF-Signal Simulators and -Receivers based on Recorded Multi GNSS Signals in Scenarios of Traffic Telematics. *Proc.26th ION GNSS*, S. 1881-1889, Nashville, Tennessee, 2013.
- Rützel 2007** RÜTZEL, Sebastian: *Ganzkörperschwingungen des sitzenden Menschen am Faber- arbeitsplatz*. Dissertation, Technische Universität Darmstadt, 2007.
- Sauer 2012** SAUER, Tomas: *Wavelets*. Vorlesungsskript, Version 1.0, letzte Änderung 26.5.2012. Onlineversion: <https://www.fim.uni-passau.de/fileadmin/files/lehrstuhl/sauer/geyer/Wavelets.pdf> (abgerufen am 24.03.2016)
- Schramm et al. 2013** SCHRAMM, Dieter; HILLER, Manfred und BARDINI, Roberto: *Modellbildung und Simulation der Dynamik von Kraftfahrzeugen*. Berlin/ Heidelberg, Springer, 2013.
- Seydel 2008** SEYDEL, Ina: *Möglichkeiten der Nutzung multivariater Analysemethoden zur Untersuchung von Verkehrsdaten*. Technische Universität Dresden, September 2008. – Diplomarbeit
- Srinivasan et al. 2006** SRINIVASAN, Manoj and RUINA, Andy: Computer optimization of a minimal biped model discovers walking and running. In: *Nature*. Vol. 439, S. 72-75, 2006.
- Stenneth et al. 2011** STENNETH, Leon; WOLFSON, Ouri, YU, Philip S.; XU, Bo: Transportation Mode Detection using Mobile Phones and GIS Information. In: *Proc. ACM SIGSPATIAL '11*. Chicago, 2011.
- Sun et al. 2010** SUN, Lin; ZHANG, Daqin; LI, Bin und LI, Shijian: Activity Recognition on an Accelerometer Embedded Mobile Phone with Varying Positions and Orientations. In: Yu et al. (Eds): *UIC 2010, LNCS 6406*, pp. 548-562. Berlin/ Heidelberg, Springer, 2010.
- Theodoridis et al. 2009** THEODORIDIS, Sergios und KOUTROUMBAS, Konstantinos: *Pattern Recognition*. 4. Aufl., San Diego: Academic Press, 2009.
- Thompson et al. 2010** THOMPSON, Chris; WHITE, Jules; DOUGHERTY, Brian; ALBRIGHT, Alan; SCHMIDT, Douglas C.: Using Smartphones to Detect Car Accidents and Provide Situational Awareness to Emergency Responders. In: *Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering*, Springer, Heidelberg, 2010.

- Tönjes et al. 2012** TÖNJES, Stefan; KÜSTER, Andreas und RÜSSEL, Alexander: SMART-WAY: A mobile navigation system for public transport. In: *ITS World Congress 2012*, Wien, 2012.
- Tränkler et al. 2014** TRÄNKLER, Hans-Rolf und REINDL, Leonhard M. (Hrsg.): *Sensortechnik. –Handbuch für Praxis und Wissenschaft*. 2. Aufl., Berlin, Heidelberg: Springer, 2014.
- Van Ly et al. 2013** VAN LY, Minh; MARTIN, Sujitha und TRIVEDI, Mohan M.: Driver Classification and Driving Style Recognition using Inertial Sensors. In: *Proc. 2013 IEEE IV*, June 23-26, 2013, Gold Coast, Australia.
- von Gierke 1988** VON GIERKE, Henning E.: To predict the body's strength. In: *Aviation Space & Environ. Med.*, Vol. 59, S. 107-115, 1988.
- von Hünenbein 2013** VON HÜNERBEIN, Karin und LANGE, Werner: Userfriendly, real time remote control of satellite navigation signal simulation by emulating realistic flight trajectories and driving routes with standard flight simulator. In: *European J. of Navigation*, Vol. 11, No. 2, S. 4-10, August 2013.
- Wang et al. 2010** WANG, Shuangquan; CHEN, Canfeng und MA, Jian: Accelerometer based transportation mode recognition on mobile phones. In: *Proc. APWCS, Shenzhen, 2010*.
- Weichert et al. 2010** WEICHERT, Norbert und WÜLKER, Michael: *Messtechnik und Messdatenerfassung*. München: Oldenbourg, 2010.
- Weidmann 1993** WEIDMANN, Ulrich: Transporttechnik der Fußgänger. In: *Schriftenreihe des IVT*, Nr. 90, 2. Aufl., Zürich, 1993.
- Welch et al. 2013** WELCH, Stephen Christopher und BARFIELD Jr., James Ronald: *Automatic alignment of a vehicle thee-axes accelerometer*. United States Patent 9128116, 8. September 2015.
- Wendel 2007** WENDEL, Jan: *Integrierte Navigationssysteme – Sensordatenfusion, GPS Inertiale Navigation*. München: Oldenbourg, 2007.
- Werner 2014** WERNER, Martin: *Indoor Location-Based Services*. Cham: Springer, 2014.
- Wheatstone 1843** WHEATSTONE, Charles: The Bakerian Lecture: An Account of Several New Instruments for Determining the Constants of a Voltaic Circuit. In: *Phil. Trans. Royal Soc. London*, Vol. 133, S. 303-327, 1843.
- Widhalm et al. 2012** WIDHALM, Peter; NITSCHKE, Philippe; BRÄNDLE, Norbert: Transport Mode Detection with Realistic Smartphone Sensor Data. In: *Proc. ICPR 2012*, 11.-15. November, Tsukuba, Japan, 2012.
- Willumeit 1998** WILLUMEIT, Hans-Peter: *Modelle und Modellierungsverfahren in der Fahrzeugdynamik*. BG. Teubner, Stuttgart, Leipzig, 1998.

- Witten et al. 2007** WITTEN, Ian H. und EIBE, Frank: *Data Mining – Practical Machine Learning Tools and Techniques*. 2. Aufl., Morgan Kaufmann series in data management systems. San Francisco: Elsevier, 2005.
- Wolfers 1872** WOLFERS, Jakob Philipp: *Sir Isaac Newtons's Mathematische Principien der Naturlehre*. Berlin: Oppenheim, 1872.
- Yakovitz 1970** YAKOVITZ, Sydney: Unsupervised Learning and the Identification of Finite Mixtures. In: *IEEE Trans. on Information Theory*. Vol. 16, 1970, S. 330-338.
- Yang 2009** YANG, Jun: Toward Physical Activity Diary: Motion Recognition Using Simple Acceleration Features with Mobile Phones. In: *IMCE'09*, Beijing, October 23, 2009.
- Yang et al. 2010** YANG, Yu-Chieh; TOIDA, Tatsuo und HONG, Chin-Ming: Transportations Prediction Using Build-in Triaxial Accelerometer in Cell Phone. In: *Proc. BAI 2010, Kitakyushu*, 2010.
- Živanović et al. 2005** ŽIVANOVIĆ, Stana; PAVIC, Aleksandar und REYNOLDS, Paul: Vibration serviceability of footbridges under human-induced excitation: a literature review. In: *J. Sound and Vibration*. Vol. 279, No. 1-2, S.1-74, 2005.
- Zöfel 2003** ZÖFEL, Peter: *Statistik für Wirtschaftswissenschaftler – im Klartext*. München: Person Studium, 2003.

Anhang

Anhang A Zustandsmodelle für Straßenbahn




Abbildung 76: Achsenbezogene Bewegungszustände als Detaillierung für den Bewegungsmodus „Straßenbahn“ (M3b)




Abbildung 77: Zustandsgraph für Bewegungszustände in x-Richtung eines Signals als Detaillierung für den Bewegungsmodus „Straßenbahn“ (M3b)




Abbildung 78: Zustandsgraph für Bewegungszustände in y-Richtung eines Signals als Detaillierung für den Bewegungsmodus „Straßenbahn“ (M3b)




Abbildung 79: Zustandsgraph für Kurzzeit-Bewegungszustände in z-Richtung eines Signals als Detaillierung für den Bewegungsmodus „Straßenbahn“ (M3b)




Abbildung 80: Zustandsgraph für Langzeit-Bewegungszustände in z-Richtung eines Signals gemessen in einer Straßenbahn

Anhang B Wahrscheinlichkeitsbasierte Klassifikatorwirksamkeitsbetrachtung

Die Wahrscheinlichkeit eines Klassifikators, für eine Menge an Entscheidungen die korrekte Entscheidung getroffen zu haben, wird mit P_{korrr} bezeichnet. Sie ist eine bedingte Wahrscheinlichkeit für das Ereignis „für Klasse i entschieden“ mit der zugehörigen Wahrscheinlichkeit $P_{\text{klass}, i}$ unter der Bedingung „Klasse i ist korrekt“ mit der zugehörigen Wahrscheinlichkeit $P_{\text{ist}, i}$ und berechnet sich allgemein für K möglichen Klassen mit:

$$P_{\text{korrr}} = \sum_{i=1}^K P_{\text{ist}, i} \cdot P_{\text{klass}, i} \quad (22)$$

Für die drei betrachteten naiven Klassifikatoransätze gelten nun diese Annahmen [Partzsch et al. 2016]:

- naiver Klassifikator 1: Dieser Klassifikator zieht eine zufällige Ausgabeklasse, wobei die Entscheidung für eine der K Ausgabeklassen gleichverteilt ist. Also gilt $P_{\text{klass}, i} = 1/K$; die Wahrscheinlichkeit einer korrekt vorhergesagten Klasse kann mit Hilfe der Anzahl an Klassen K berechnet werden mit

$$P_{\text{korrr}, N1} = 1/K \sum_{i=1}^K P_{\text{ist}, i} = 1/K \quad (23)$$

da $\sum_{i=1}^K P_{\text{ist}, i} = 1$ ist.

- naiver Klassifikator 2: Dieser Klassifikator zieht eine zufällige Ausgabeklasse unter der Annahme, dass die Wahrscheinlichkeit der Ausgabeklassen $P_{\text{ist}, i}$ bekannt ist. Also gilt $P_{\text{klass}, i} = P_{\text{ist}, i}$; die Wahrscheinlichkeit einer korrekt vorhergesagten Klasse kann dann berechnet werden mit

$$P_{\text{korrr}, N2} = \sum_{i=1}^K P_{\text{ist}, i}^2 \quad (24)$$

Um zu zeigen, dass $P_{\text{korrr}, N2}$ außer für den Fall der Gleichverteilung größer als $P_{\text{korrr}, N1}$ ist, kann folgende Eigenschaft normierter Vektorräume (ein Wahrscheinlichkeitsraum ist ein solcher normierter Vektorraum) herangezogen werden [Merziger et al. 2001]:

$$\|x \cdot y\| \leq \|x\| \cdot \|y\|. \quad (25)$$

Mit dem K -elementigen Wahrscheinlichkeitsvektor $x = (1/K \ 1/K \ \dots \ 1/K)^T$ im Falle der Gleichverteilung und dem K -elementigen Wahrscheinlichkeitsvektor $y = (P_{\text{ist}, 1} \ P_{\text{ist}, 2} \ \dots \ P_{\text{ist}, K})^T$ folgt nach kurzer Rechnung:

$$1/K \leq 1/\sqrt{K} \cdot \sqrt{\sum_{i=1}^K P_{\text{ist},i}^2} \quad (26)$$

Nach Erweiterung der Ungleichung mit \sqrt{K} und Quadrierung erhält man die gesuchte Beziehung

$$1/K \leq \sum_{i=1}^K P_{\text{ist},i}^2 \quad (27)$$

und hat somit $P_{\text{kor}, \text{N1}} \leq P_{\text{kor}, \text{N2}}$ nachgewiesen.

- naiver Klassifikator 3: Dieser Klassifikator zieht immer diejenige Ausgabeklasse mit der maximalen Wahrscheinlichkeit P_{max} . Die Wahrscheinlichkeit einer korrekt vorhergesagten Klasse beträgt dann

$$P_{\text{kor}, \text{N3}} = \sum_{i=1}^K P_{\text{ist},i} P_{\text{max}} = P_{\text{max}}, \quad (28)$$

da $\sum_{i=1}^K P_{\text{ist},i} = 1$ ist.

Sobald die $P_{\text{ist},i}$ nicht gleichwahrscheinlich sind, muss $P_{\text{kor}, \text{N3}}$ größer als $P_{\text{kor}, \text{N2}}$ sein, da die i Summanden im Falle des dritten naiven Klassifikators auf Grund des Faktors P_{max} für alle außer der höchstwahrscheinlichsten Klasse größer als im Falle des zweiten Klassifikators und für den Fall der höchstwahrscheinlichsten Klasse gleich groß sind.

Für gleichwahrscheinliche $P_{\text{ist},i}$ sind alle drei Ansätze identisch. Es gilt daher:

$$P_{\text{kor}, \text{N1}} \leq P_{\text{kor}, \text{N2}} \leq P_{\text{kor}, \text{N3}}. \quad (29)$$

Anhang C Sensoreigenschaften

C.1 Messstraßenbahn

Verbauter Beschleunigungssensor: KISTLER K-Beam Type 8393B10 [Kistler 2005]

- Bauweise: kapazitiver MEMS-Sensor
- Messbereich $\pm 10g$,
- 2,83 mg Auflösung
- Bandbreite 0 bis 180 Hz
- 200 Hz Datenrate
- Max. 5 mg/K Temperaturdrift

Das Datenverarbeitungssystem besteht aus einem NI pXi-Chassis mit NI cRio 9104 sowie passender A/D-Umsetzungskarte NI 9234.

C.2 Sensorplattform deRFnode

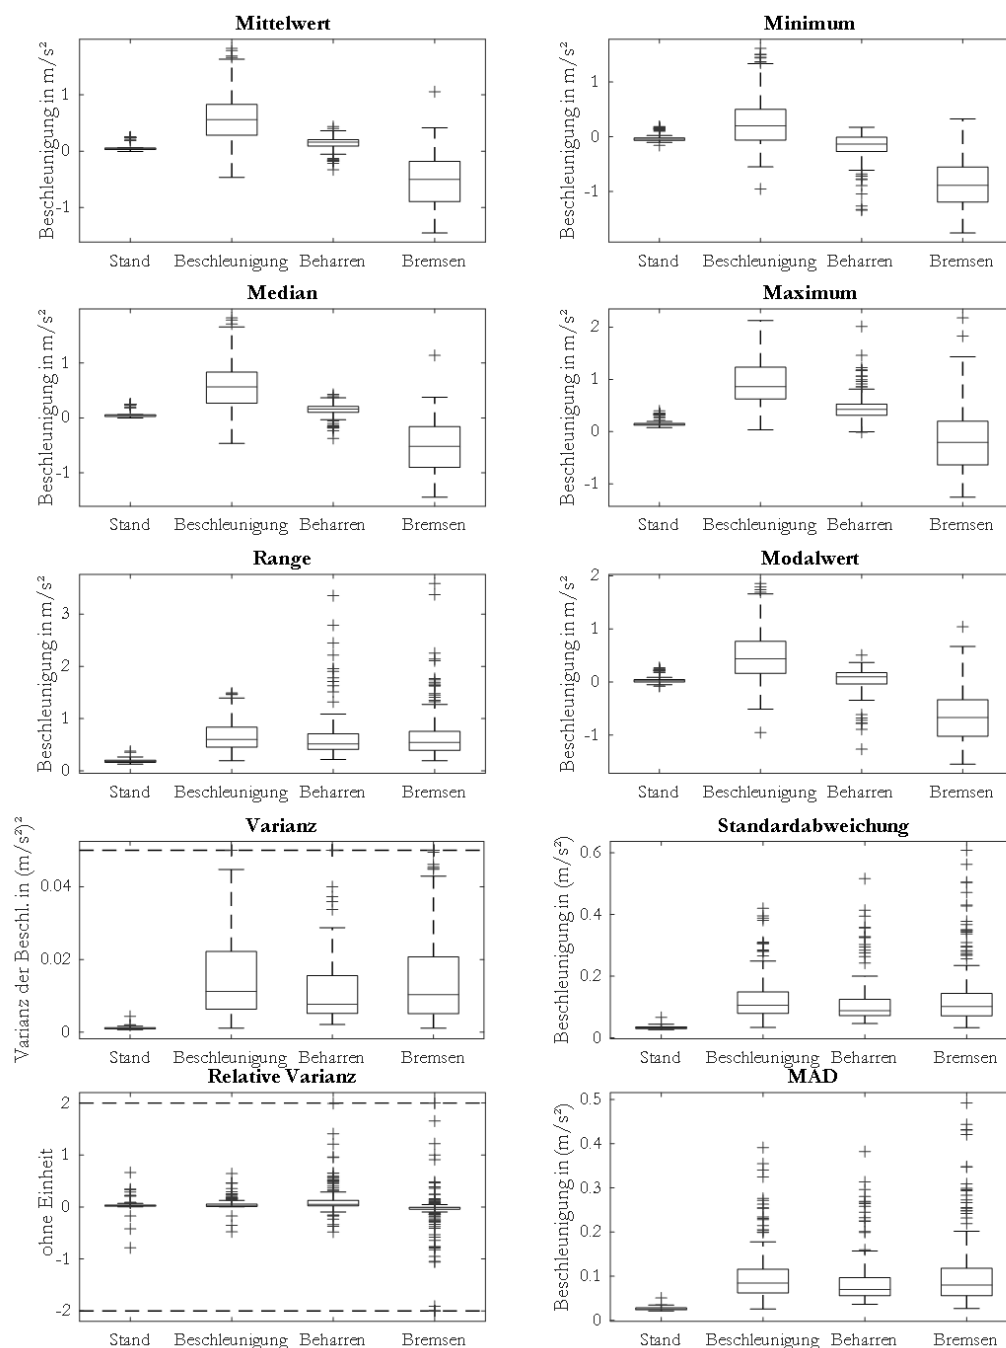
Verbauter Beschleunigungssensor: Bosch-Sensor BMA 150 [Bosch 2008]

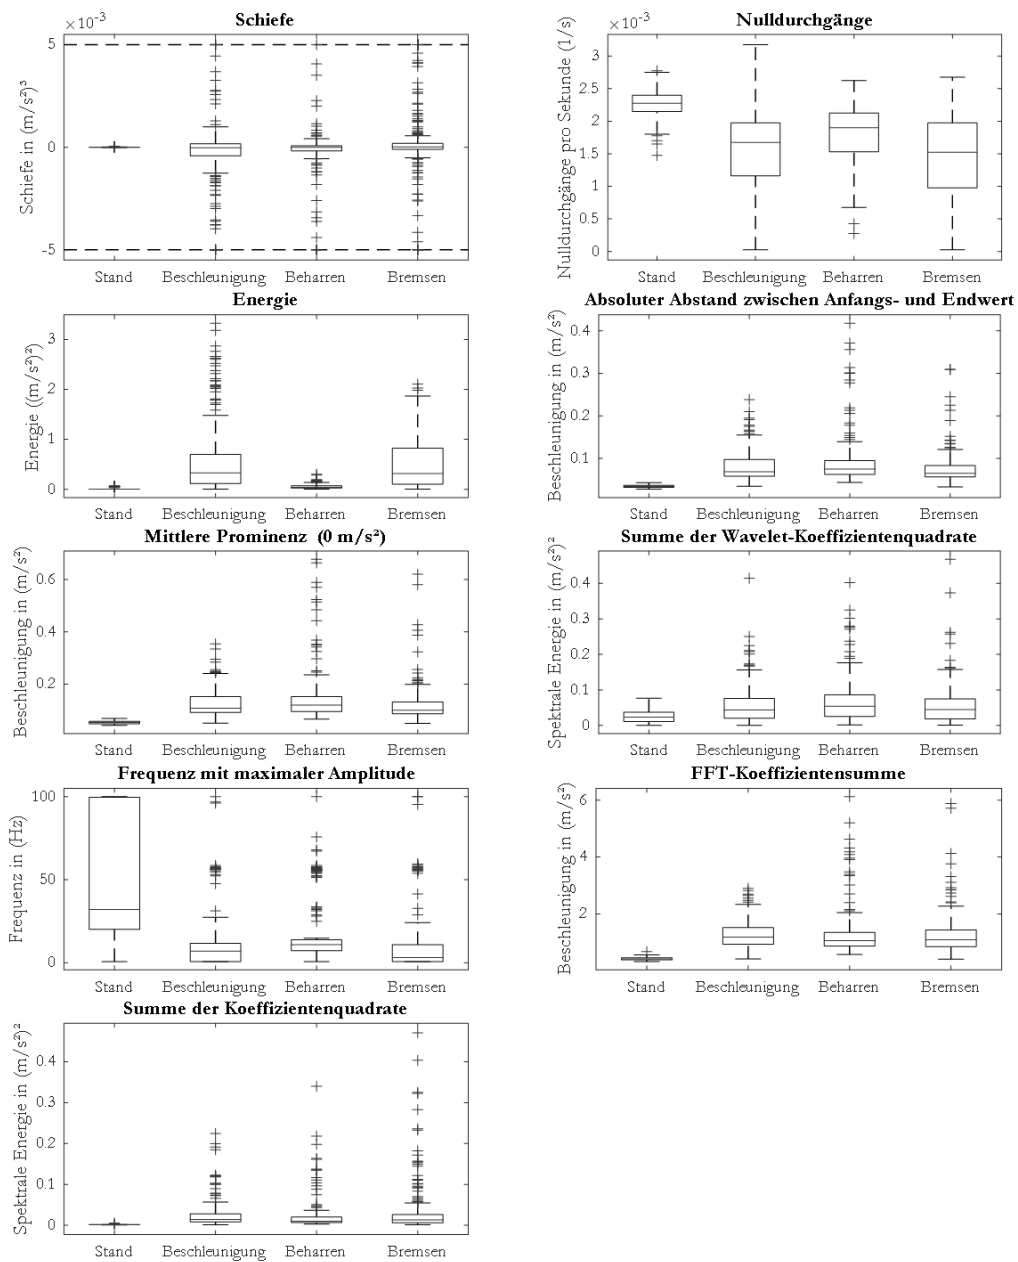
- Einstellbare Sensitivität $\pm 2g$, $\pm 4g$, $\pm 8g$ bei 10 *bit* Auflösung: zum Beispiel 4mg bei $\pm 2g$
- ± 60 mg zero-offset bei 25°C, 1mg/K Temperaturdrift
- Vorgeschalteter analoger Tiefpass mit Grenzfrequenz 1500 Hz, interne Abtastrate 3000 Hz
- Einstellbare Bandbreiten über digitalen Filter: 25/50/100/190/375/750Hz
- Maximale Datenrate: 100 Hz (begrenzt durch Board)

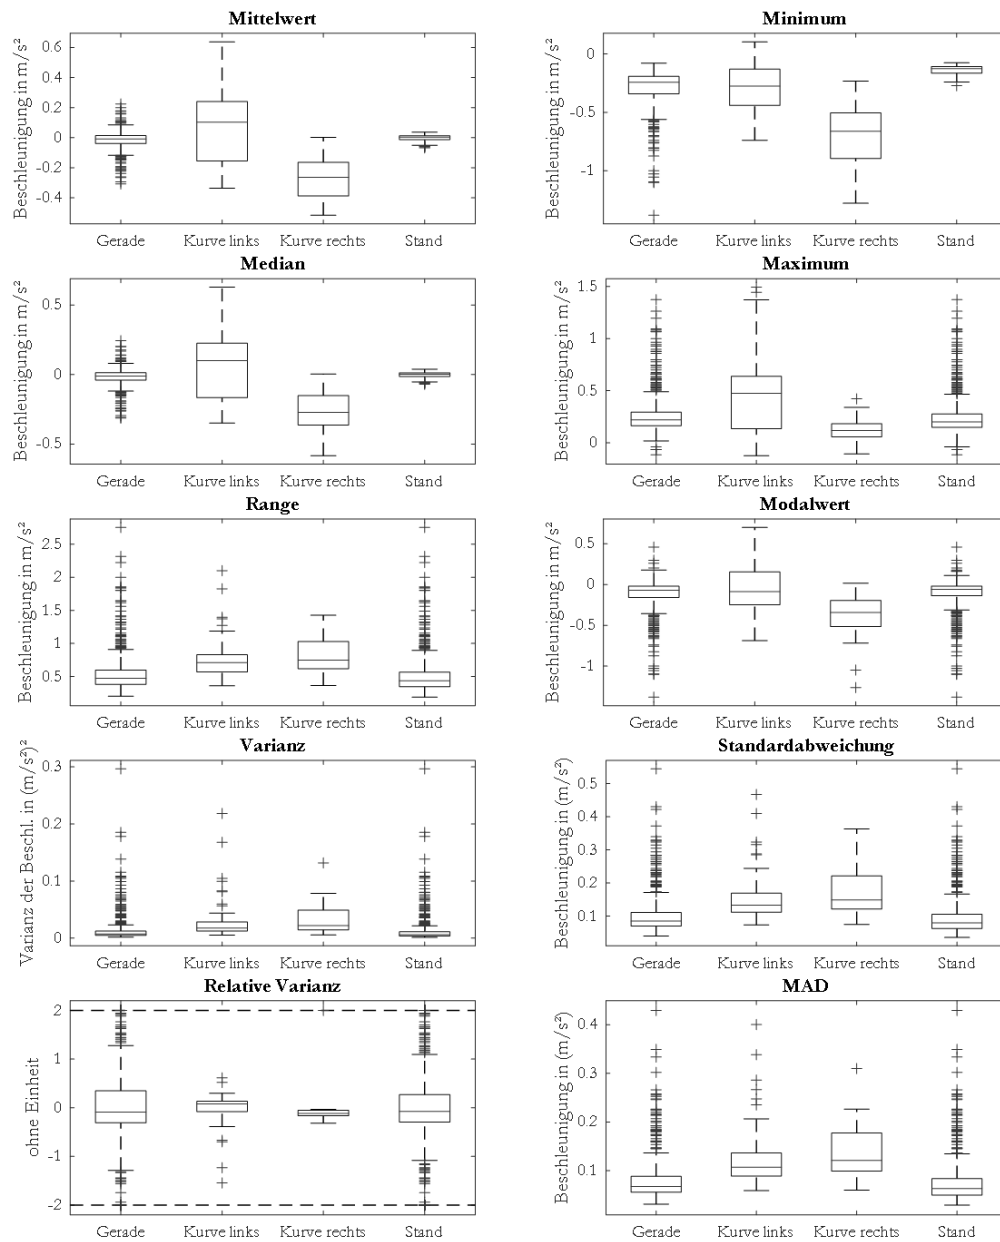
Die Messwerte können mittels USB-Schnittstelle, Treibersoftware und einer Software zum Herstellen von Verbindungen ausgelesen werden.

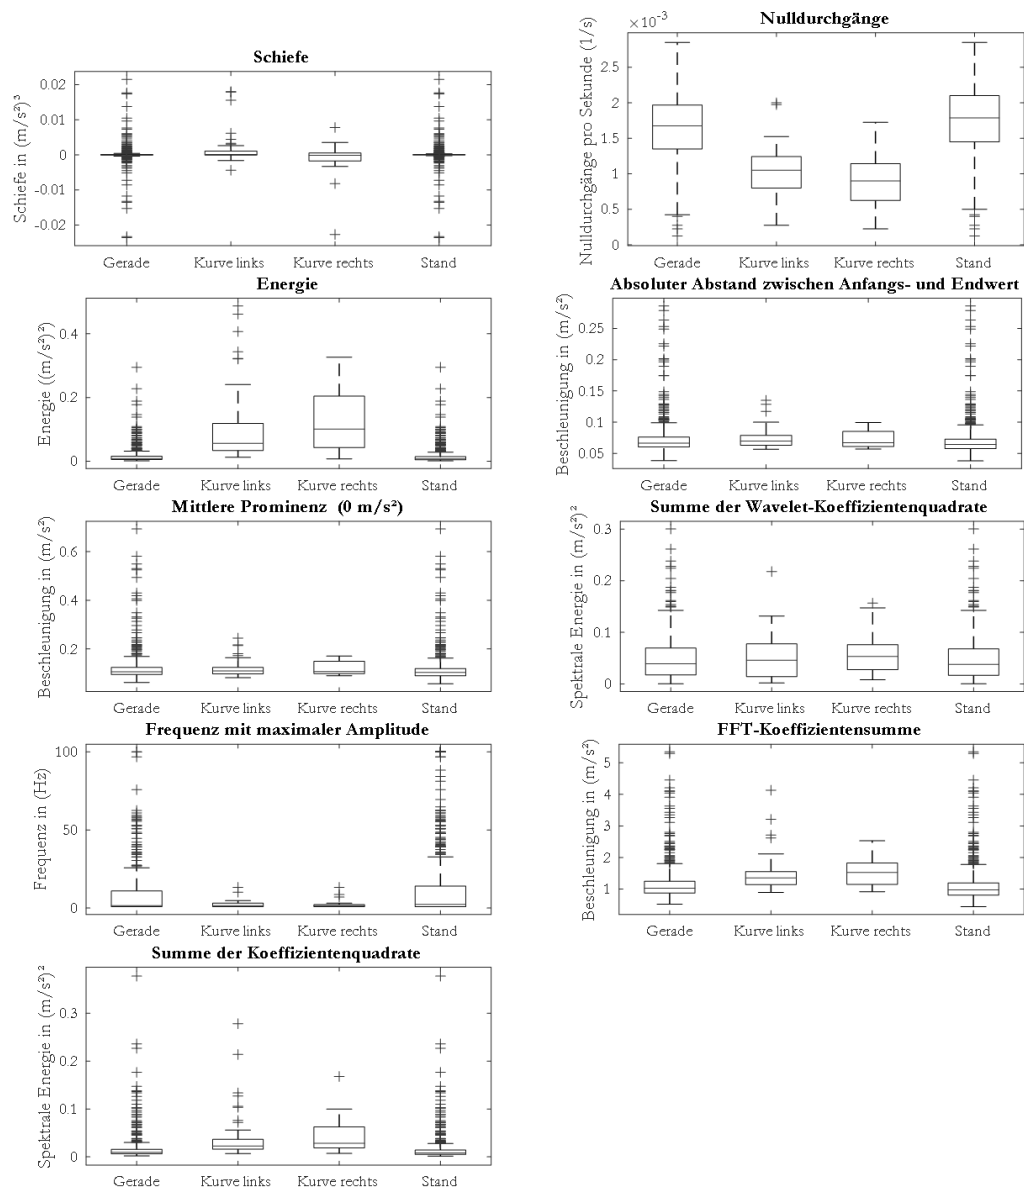
Anhang D Boxplots zur Analyse der Messstraßenbahndaten

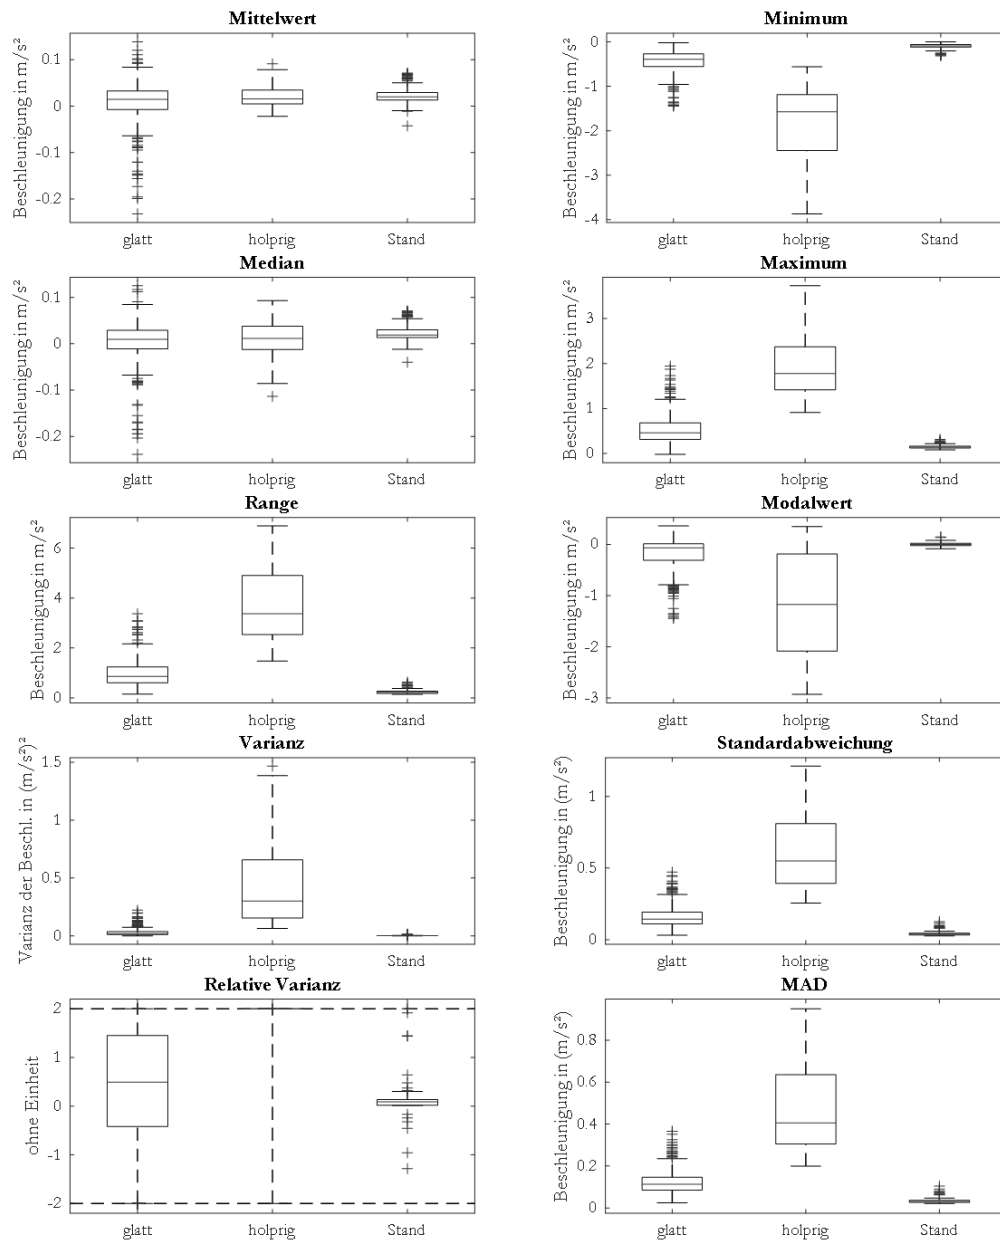
Merkmale des x -Signal Teil 1

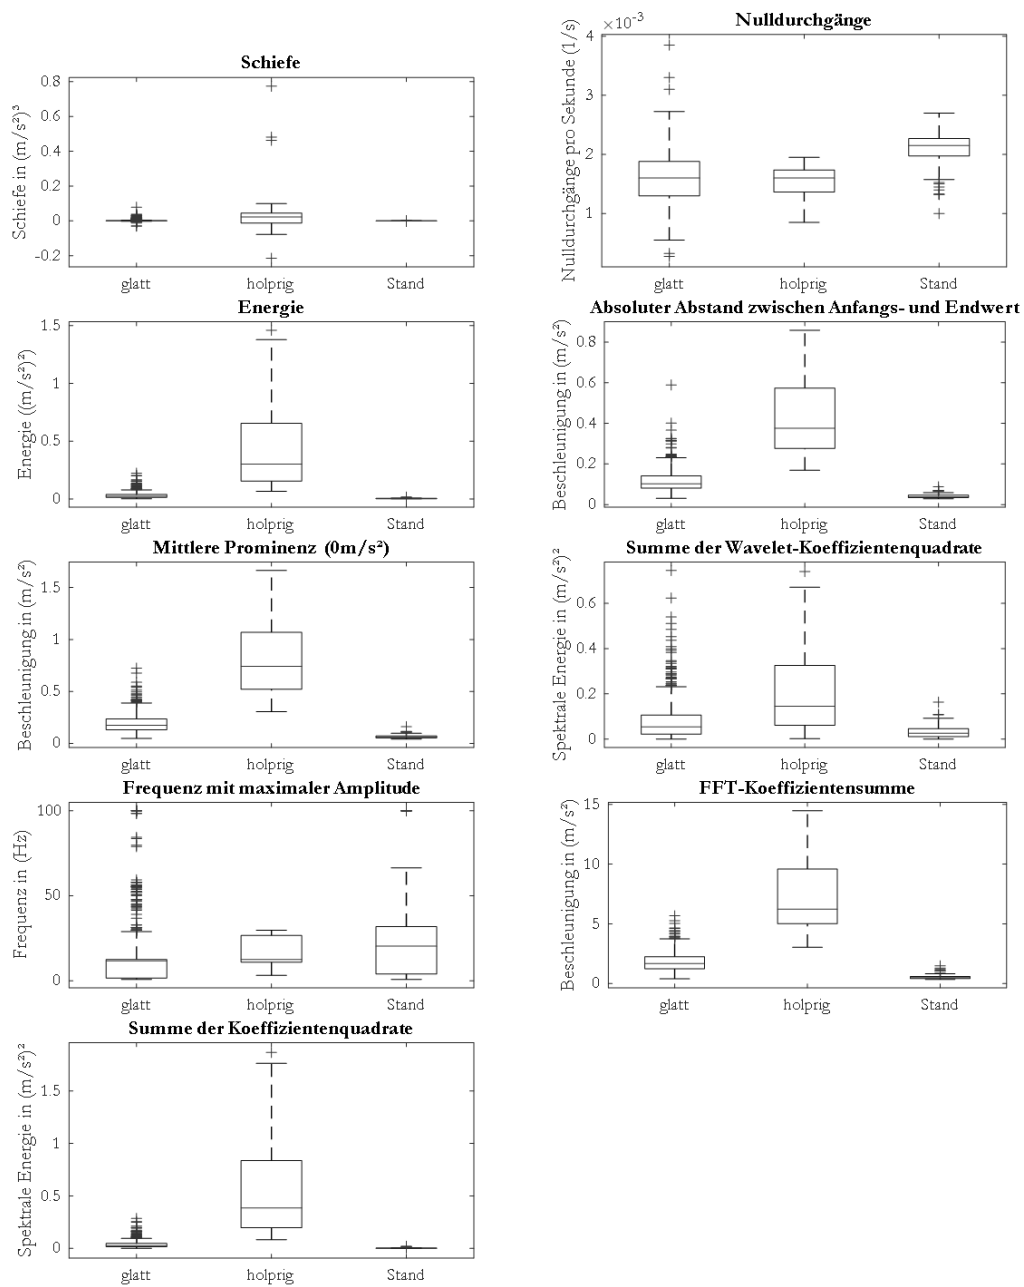


Merkmale des x -Signal Teil 2

Merkmale des y -Signals Teil 1

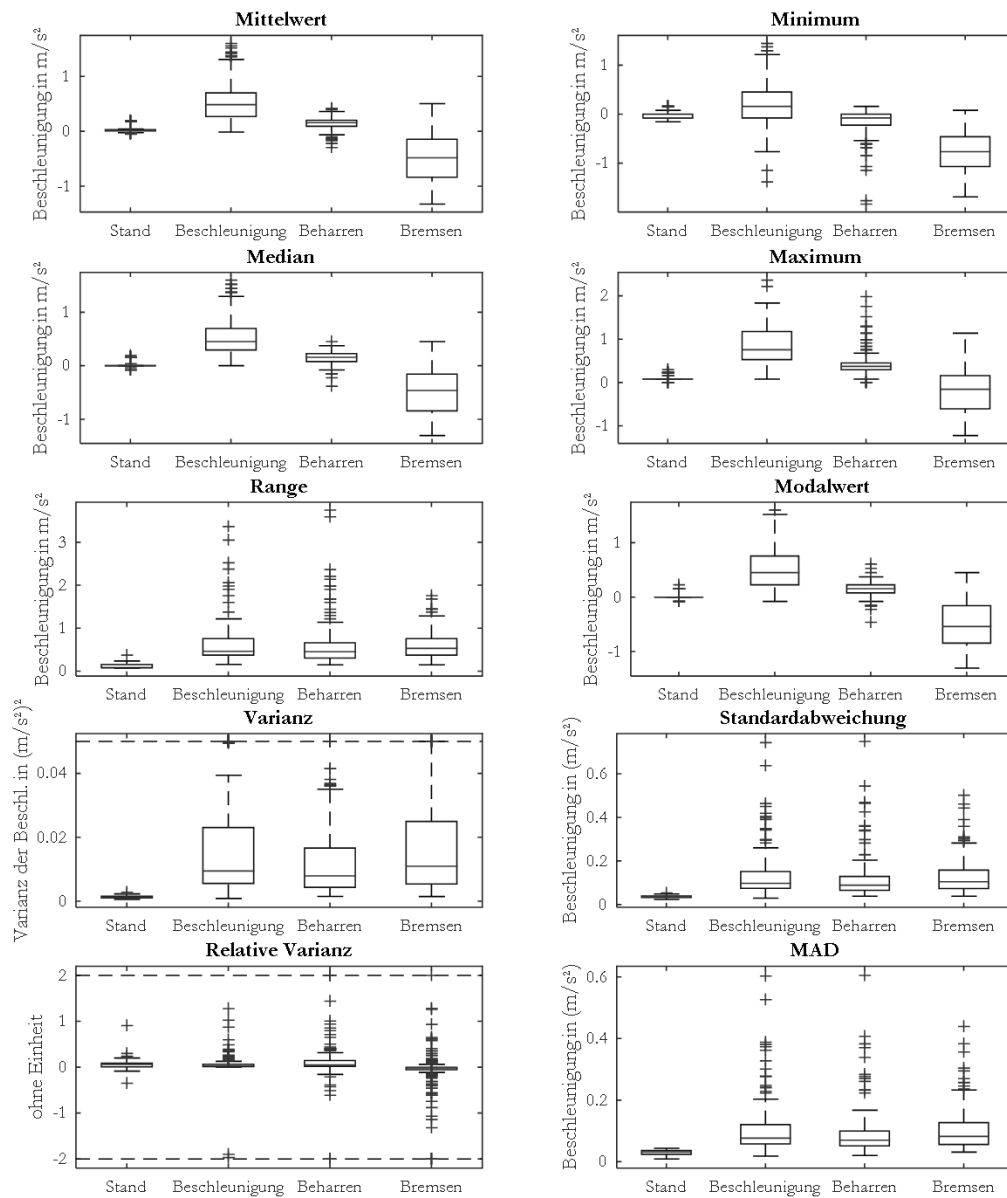
Merkmale des y -Signals Teil 2

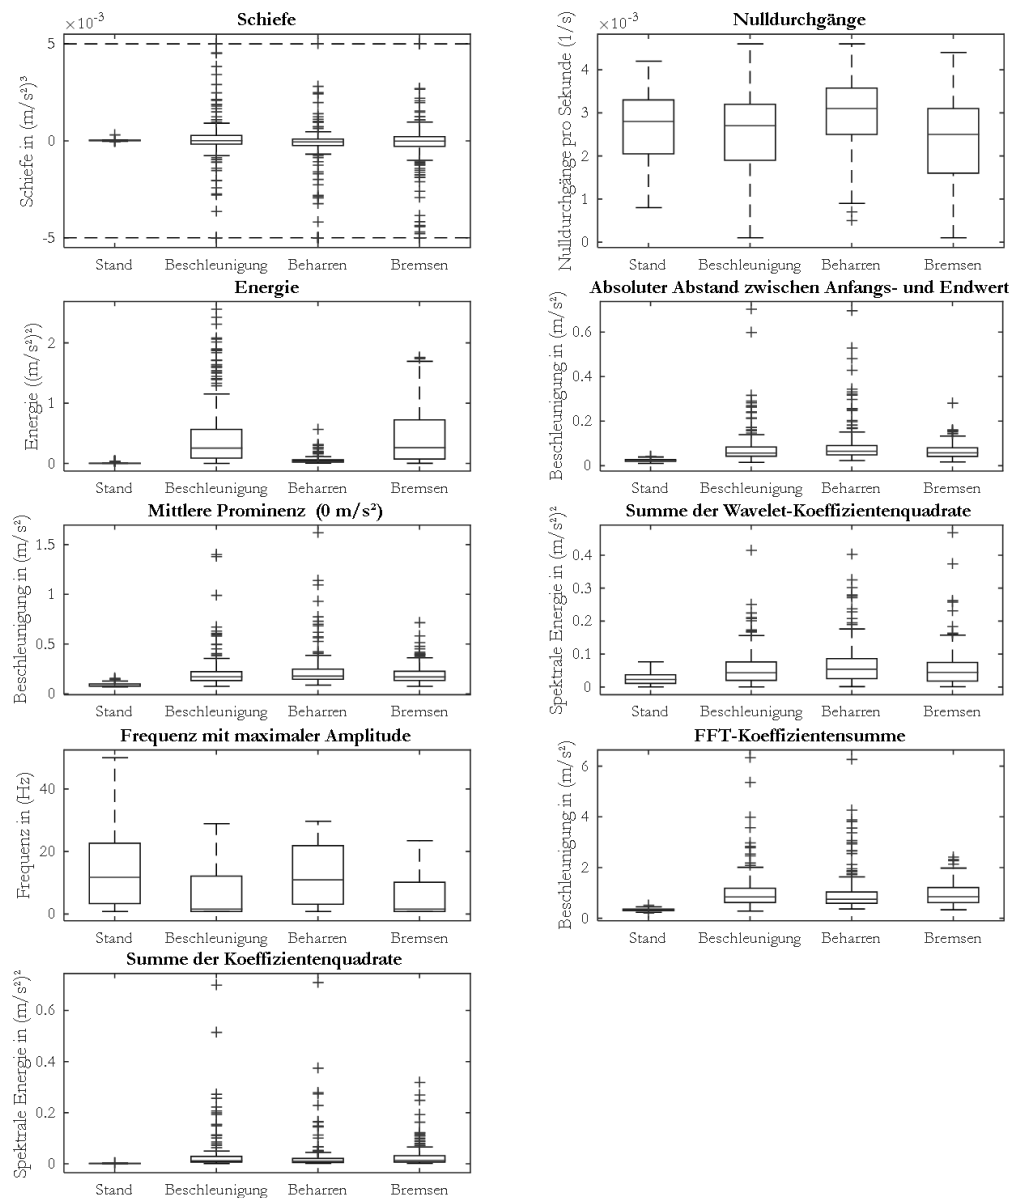
Merkmale des \ddot{x} -Signals Teil 1

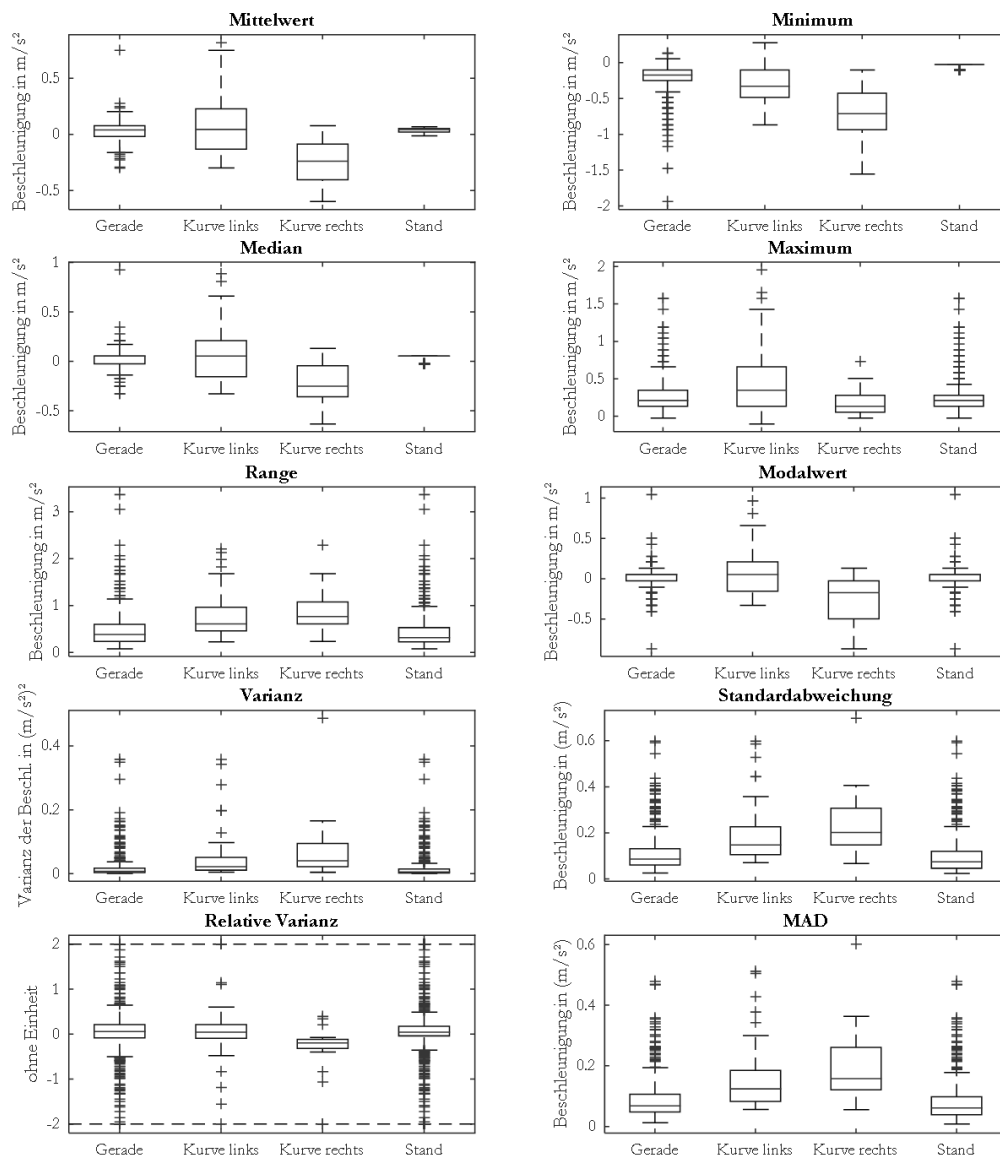
Merkmale des \tilde{z} -Signals Teil 2:

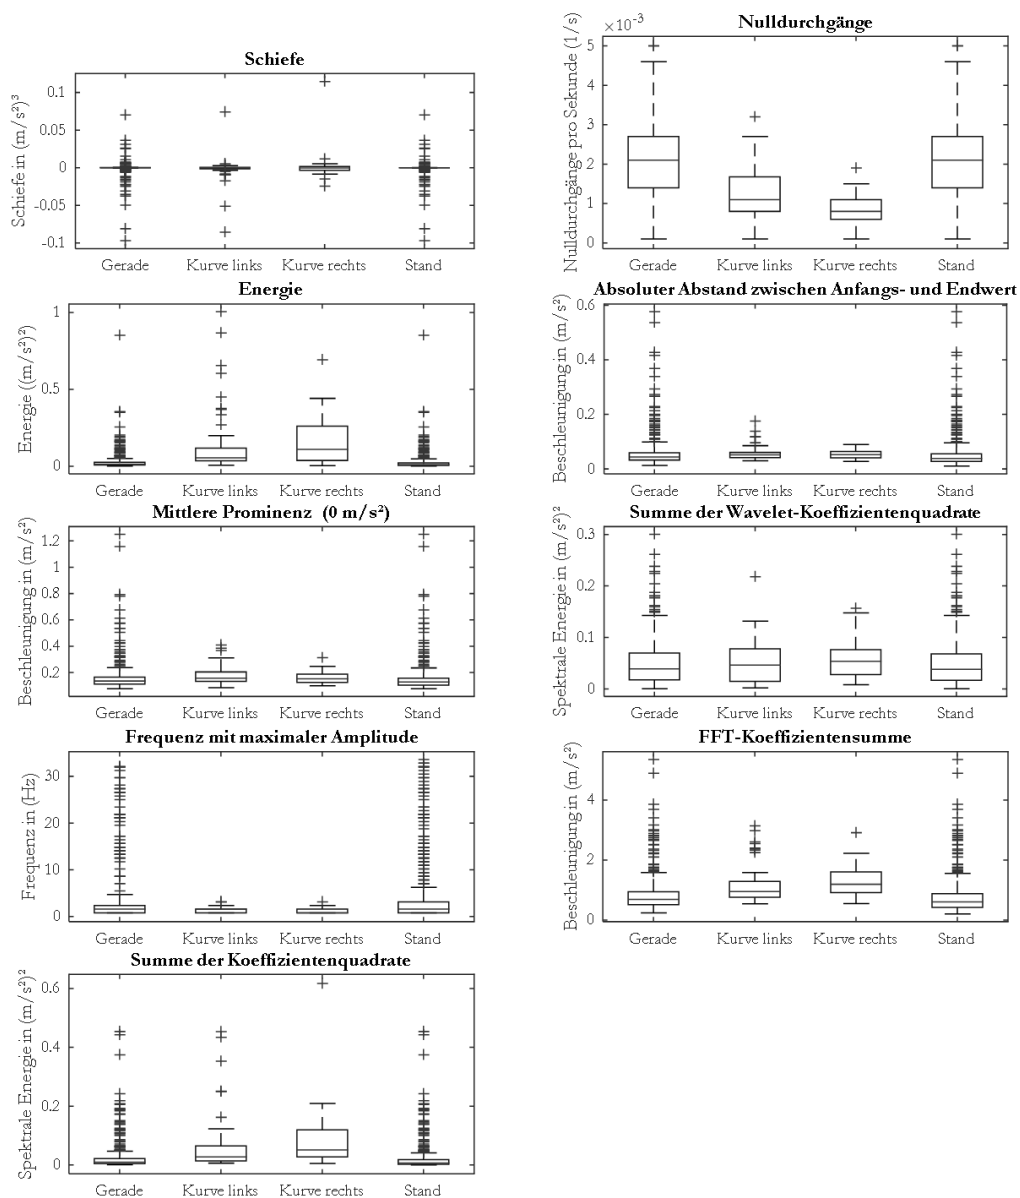
Anhang E Boxplots zur Analyse der deRFnode-Daten in der Straßenbahn

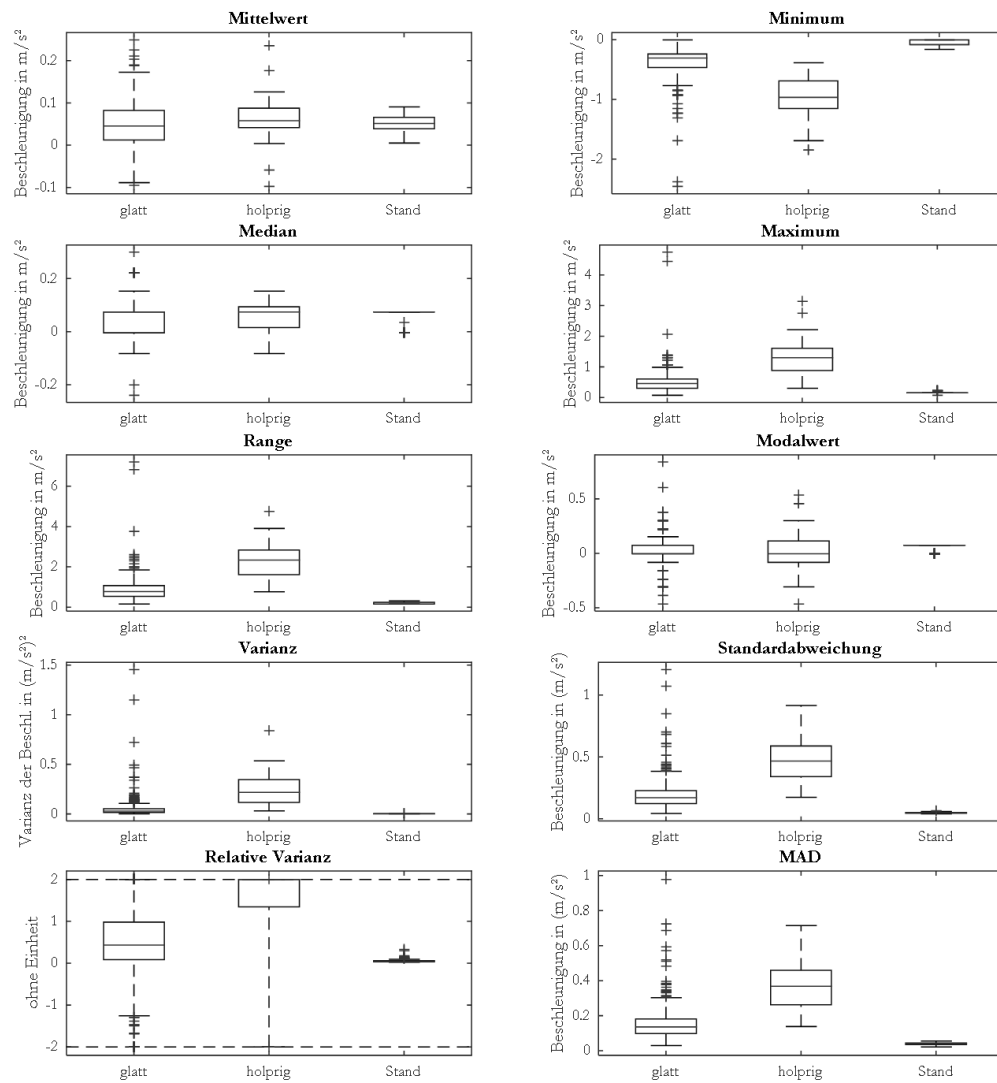
Merkmale des x -Signal Teil 1

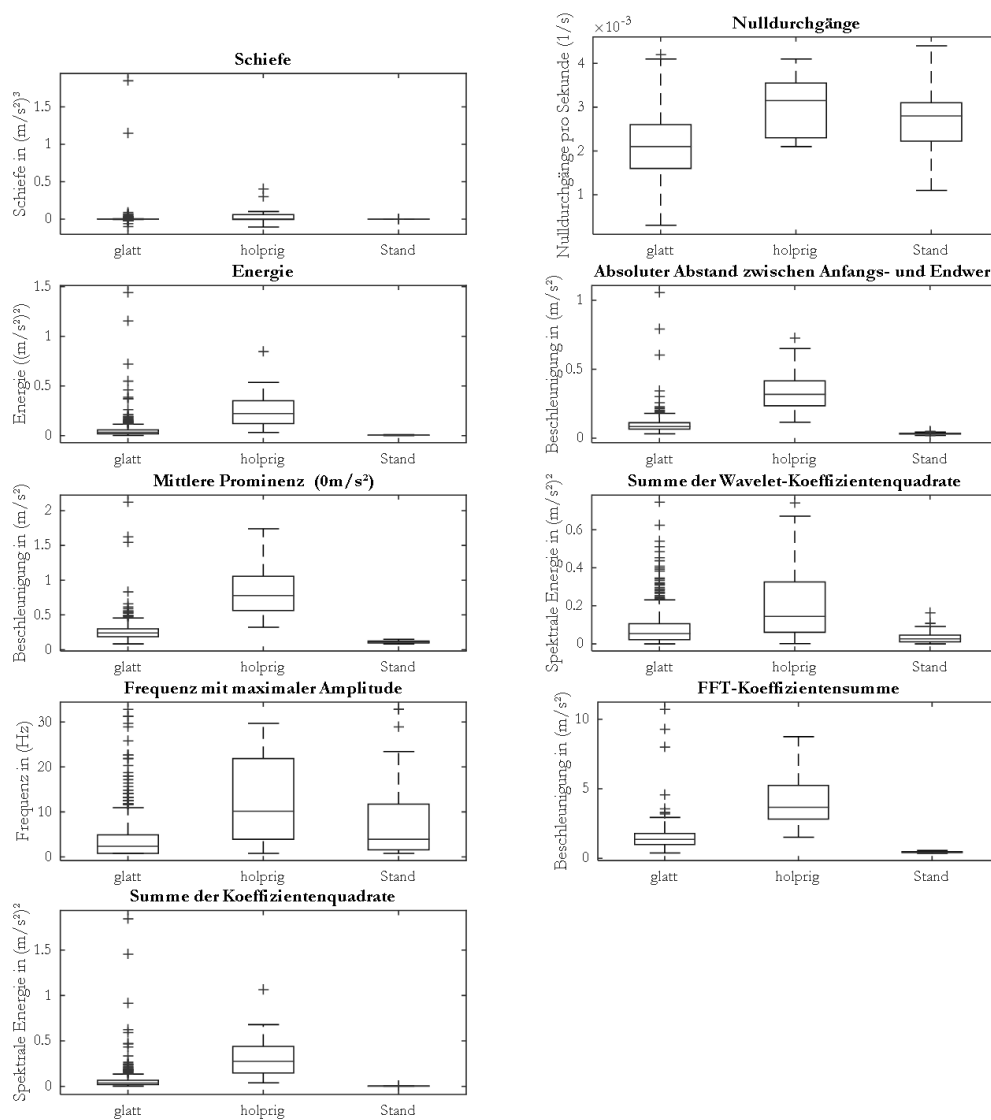


Merkmale des x -Signal Teil 2

Merkmale des y -Signal Teil 1

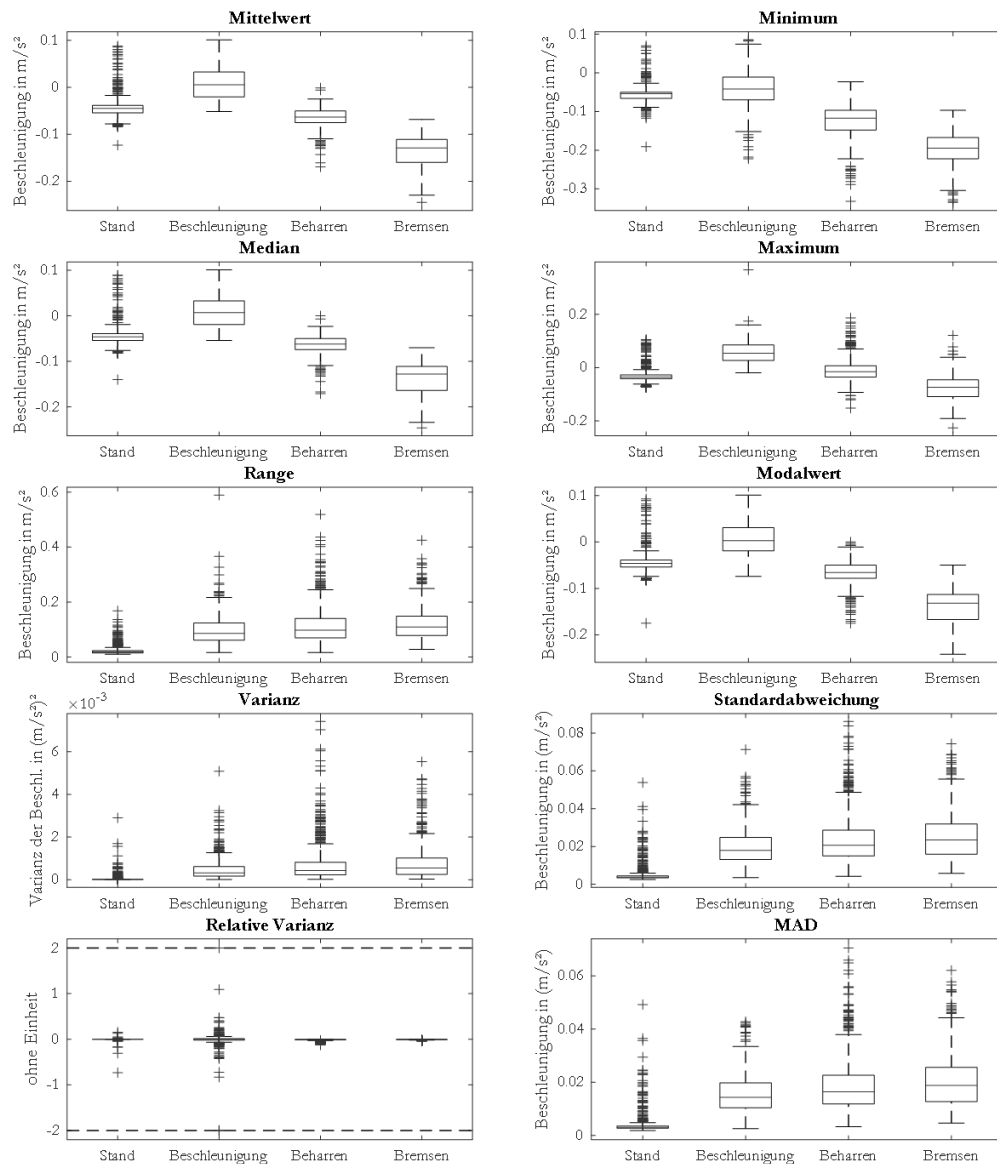
Merkmale des y -Signal Teil 2

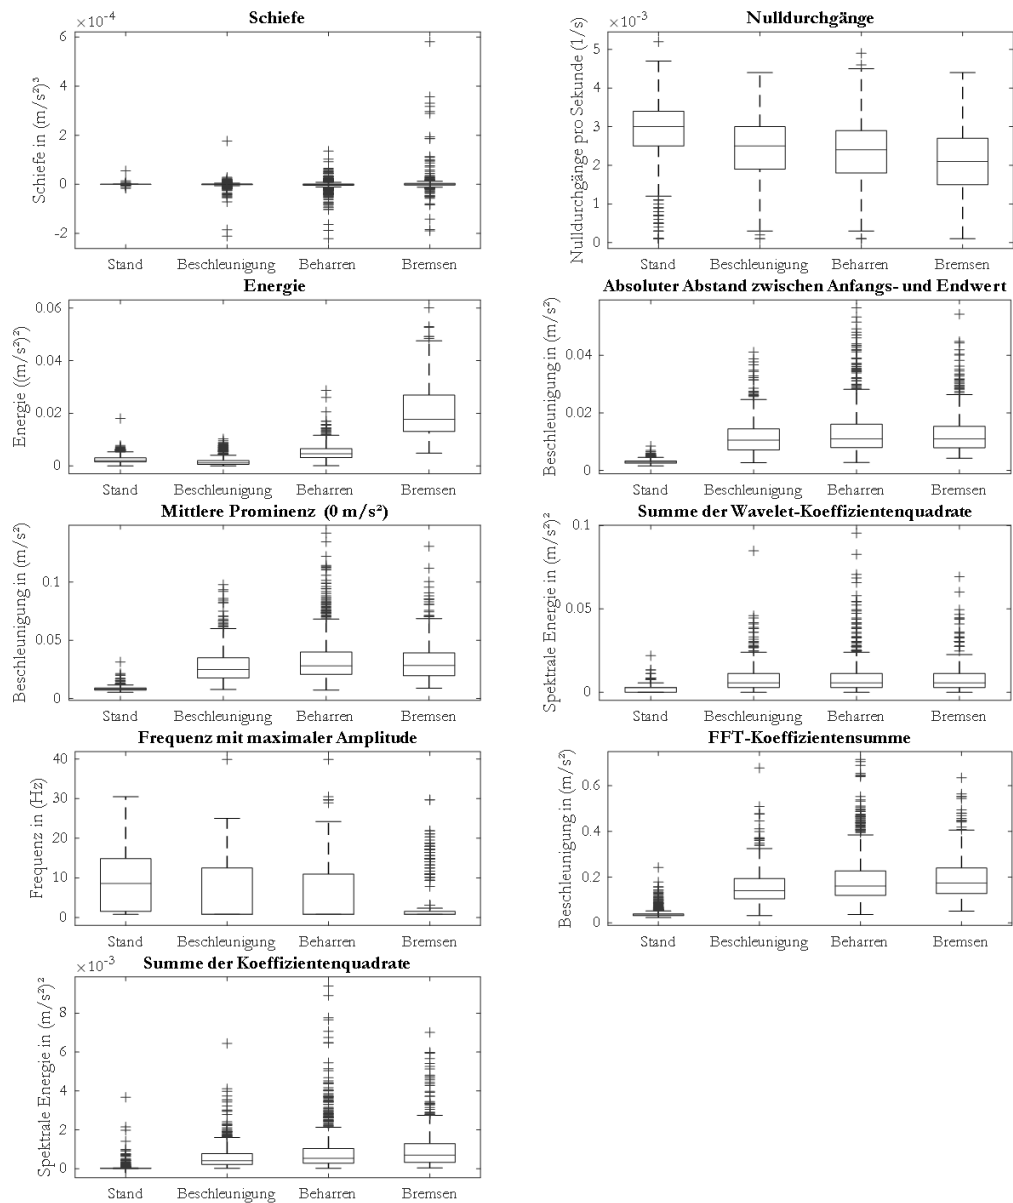
Merkmale des \tilde{z} -Signal Teil 1

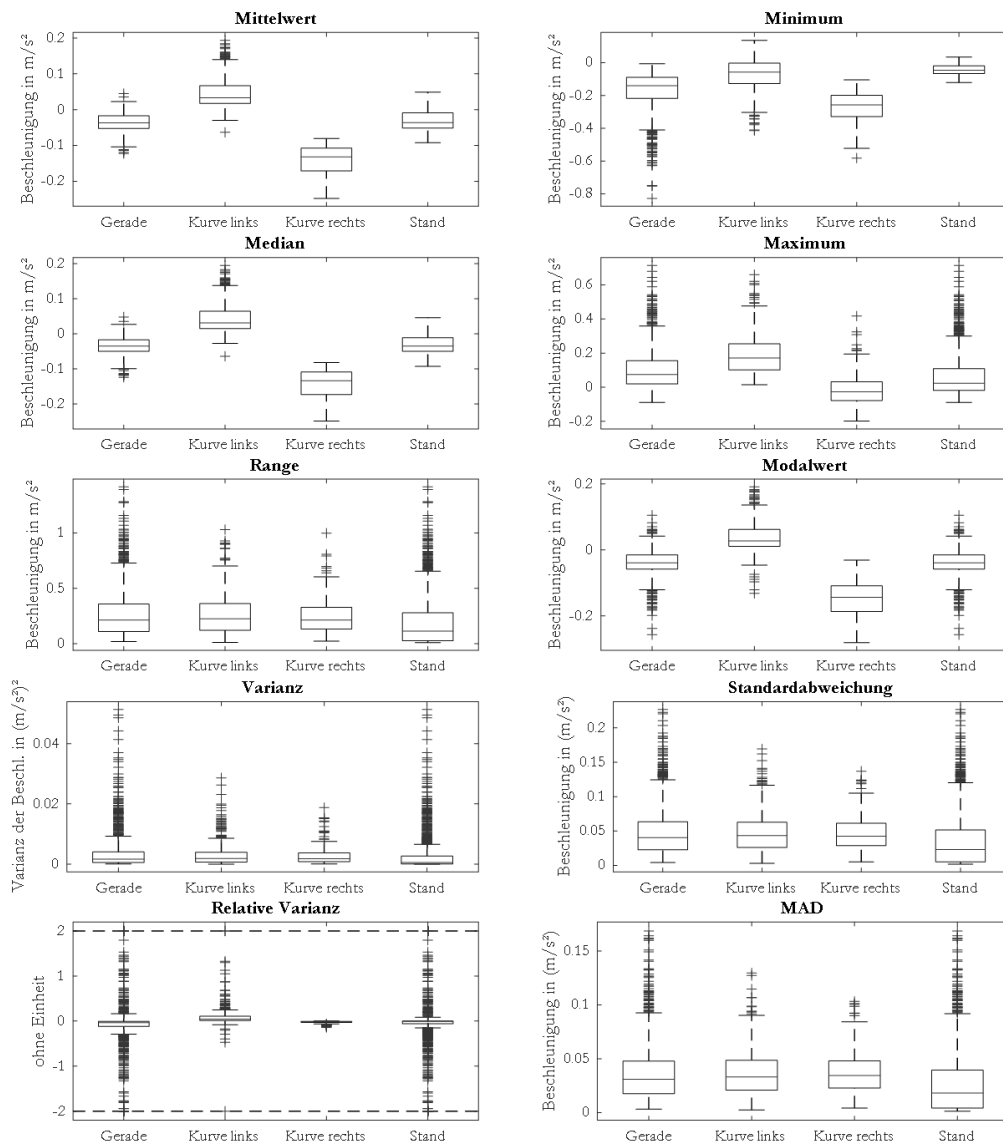
Merkmale des \tilde{z} -Signal Teil 2

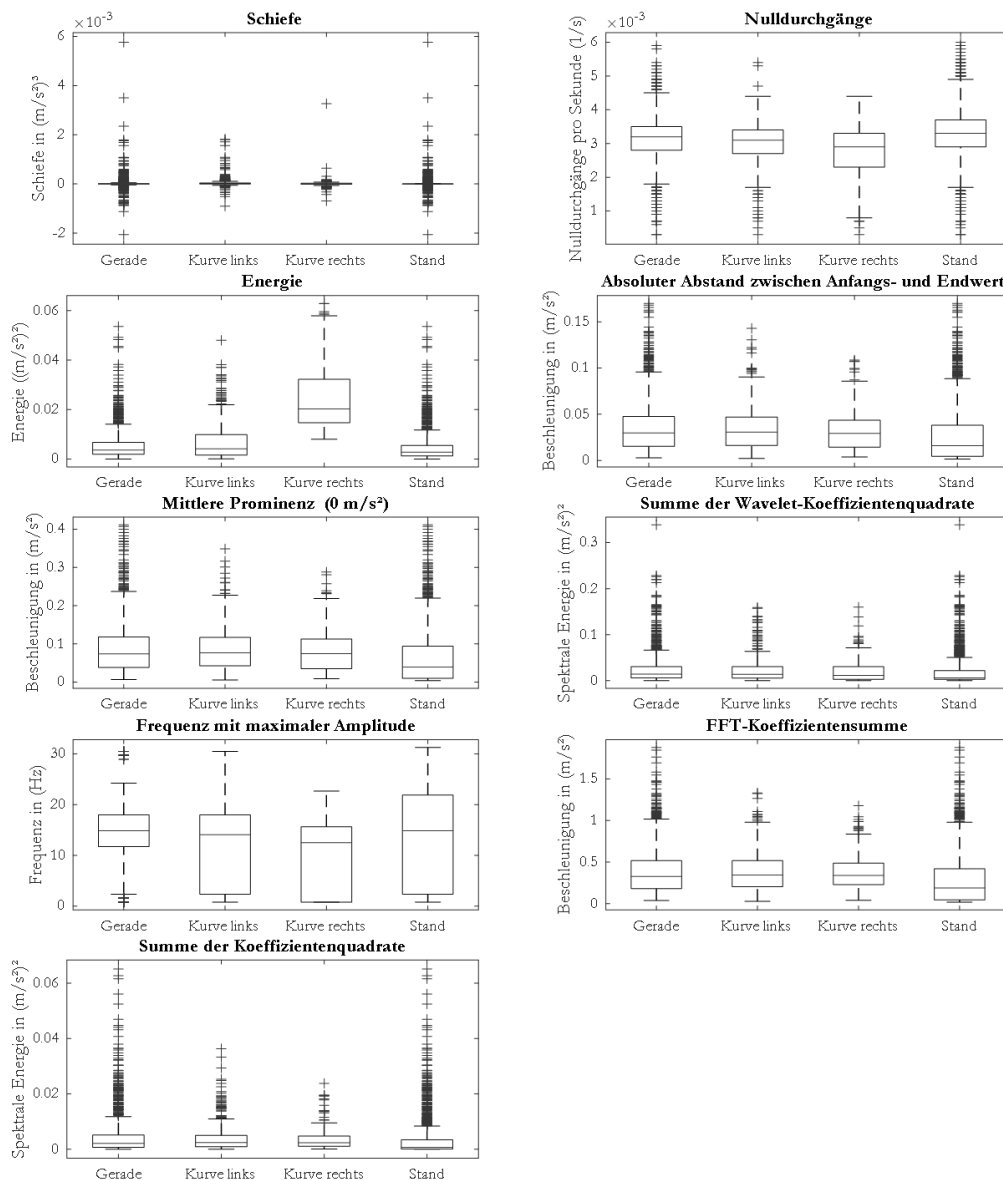
Anhang F Boxplots zur Analyse der deRFnode-Daten im Bus

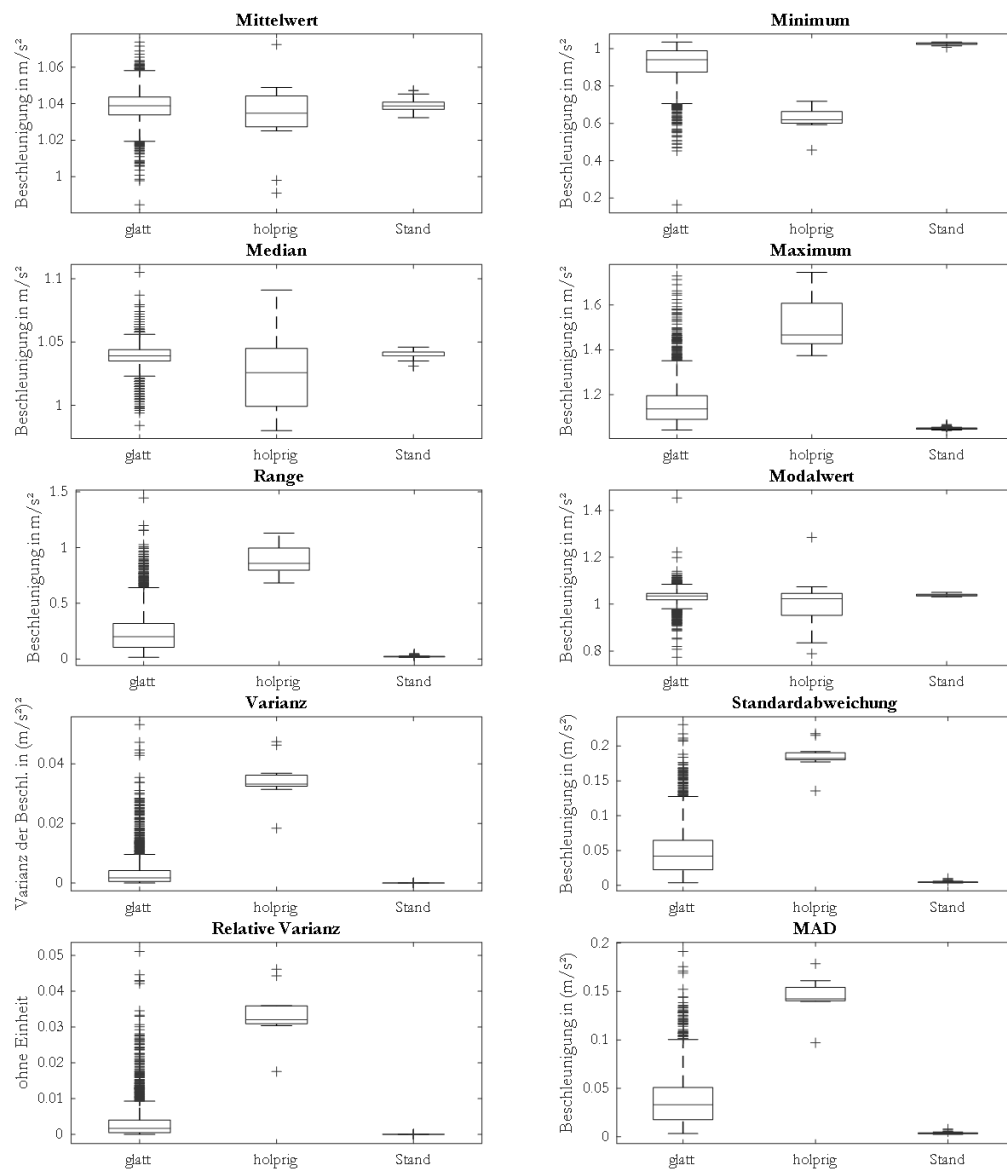
Merkmale des x -Signal Teil 1

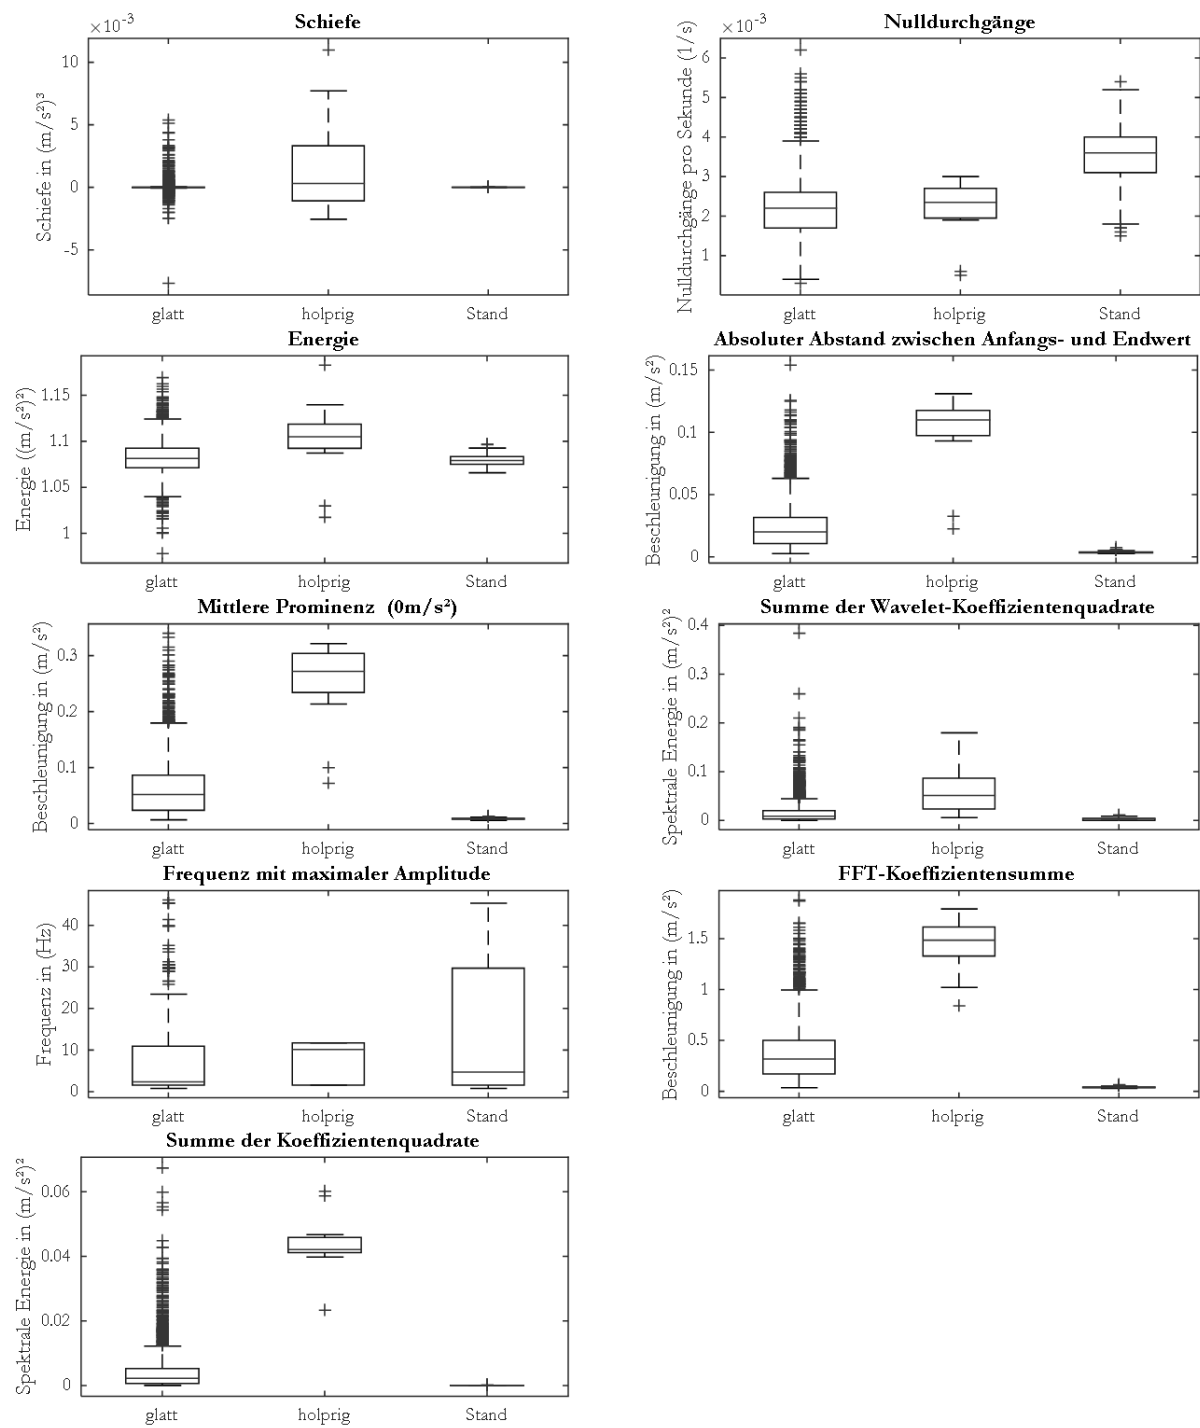


Merkmale des x -Signal Teil 2

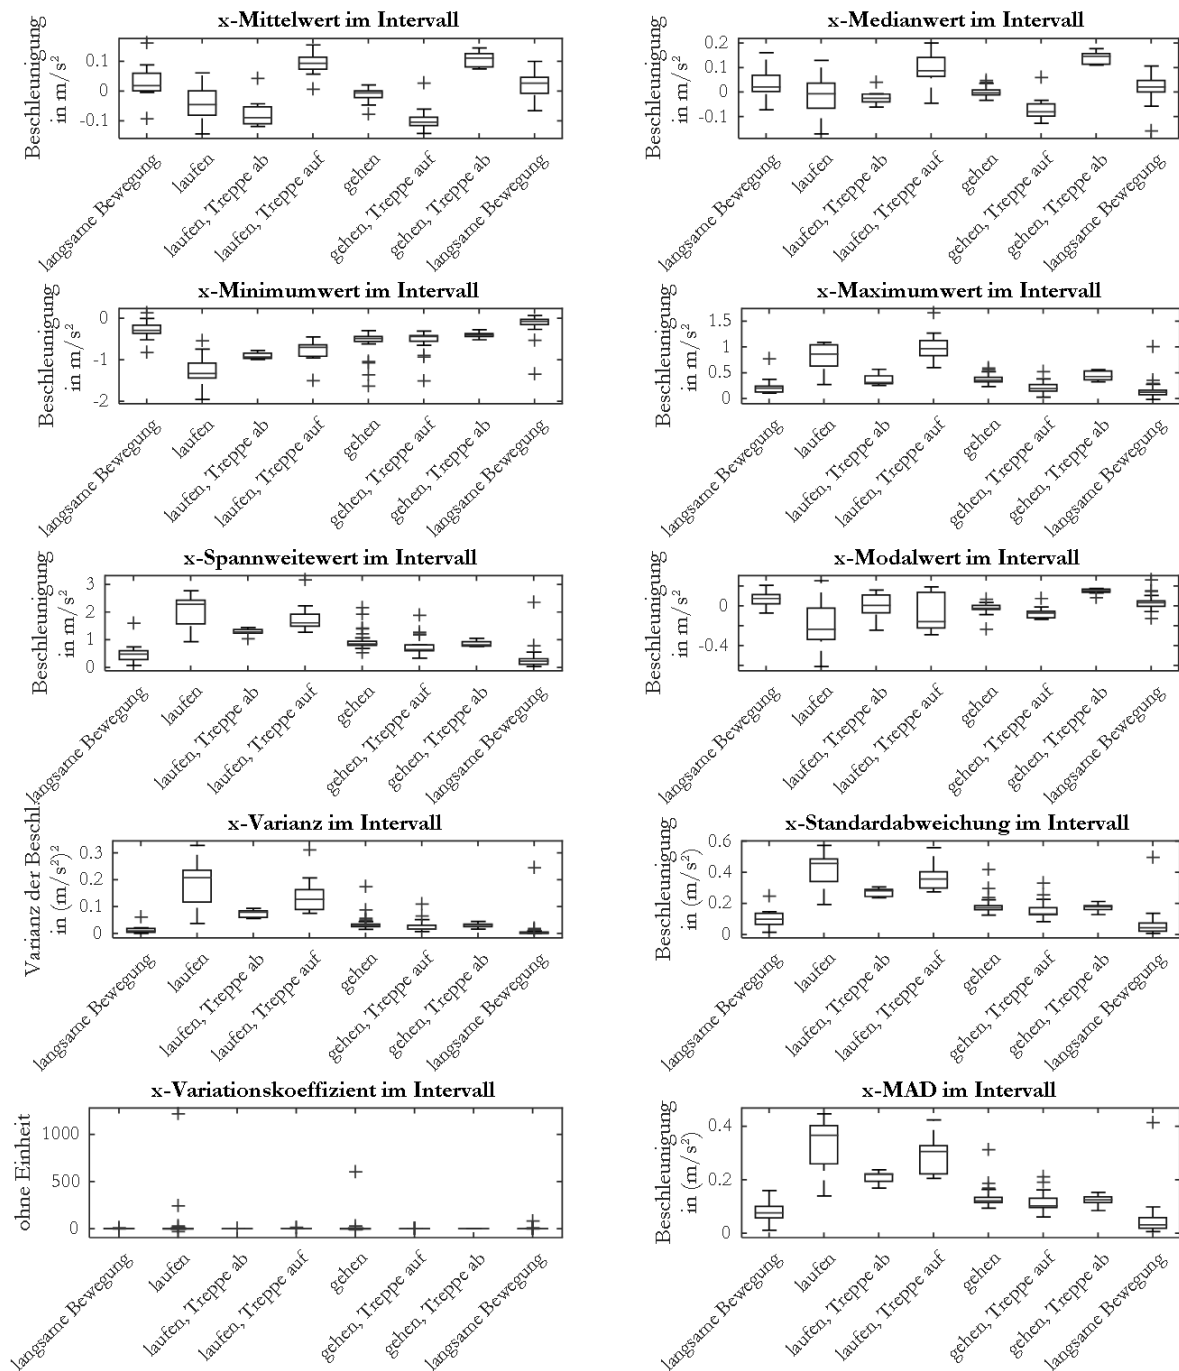
Merkmale des y -Signal Teil 1


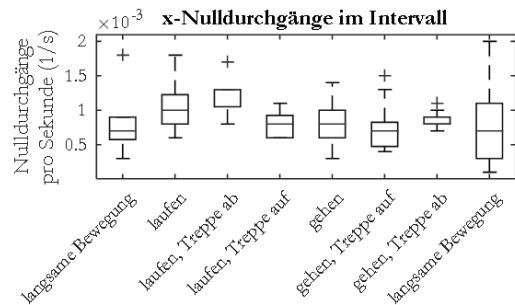

Merkmale des y -Signal Teil 2

Merkmale des \tilde{z} -Signal Teil 1



Merkmale des \tilde{z} -Signal Teil 2

Anhang G Boxplots zur Analyse der deRFnode-Daten bei Personenbewegung







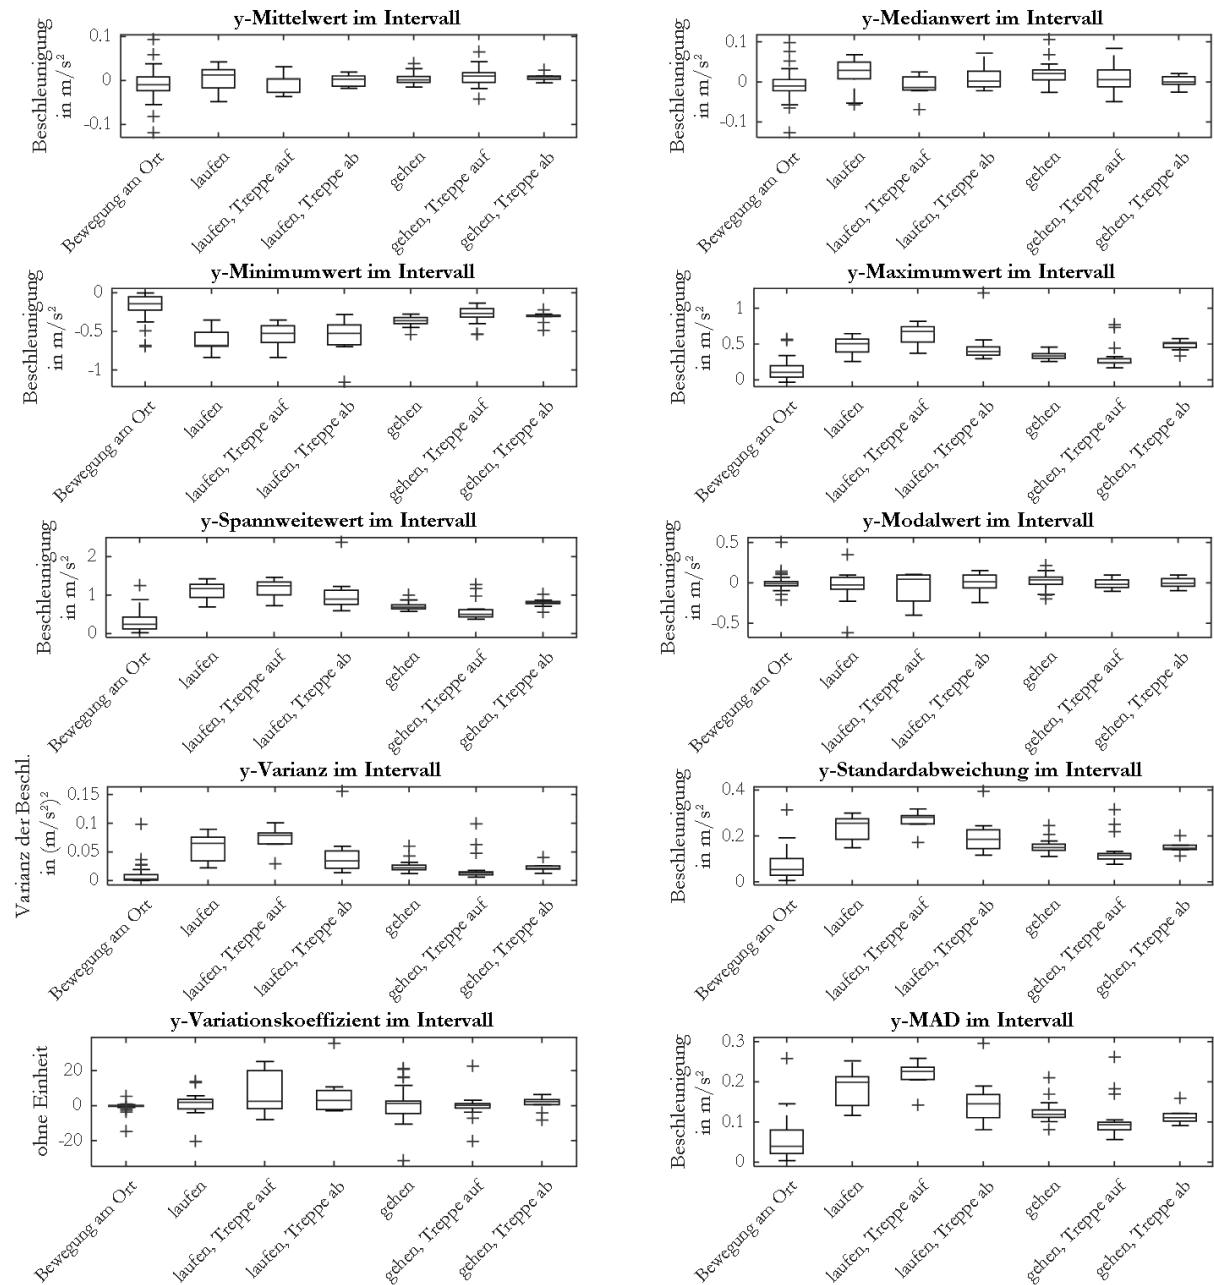


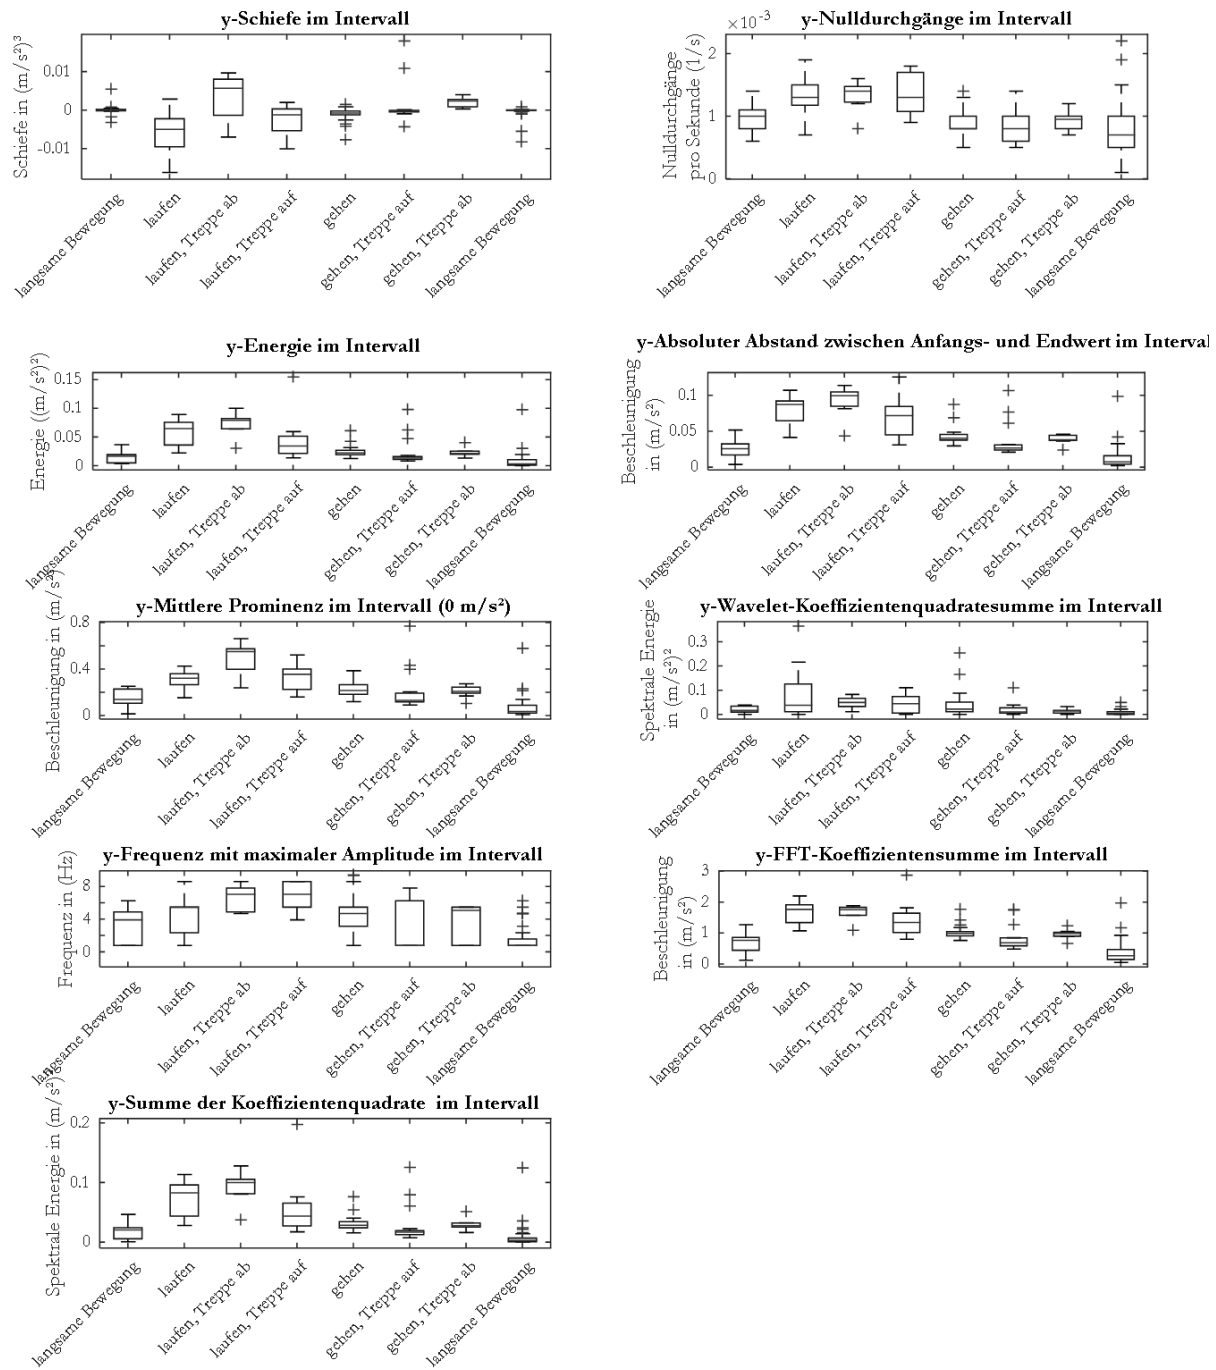
x-Absoluter Abstand zwischen Anfangs- und Endwert im Intervall

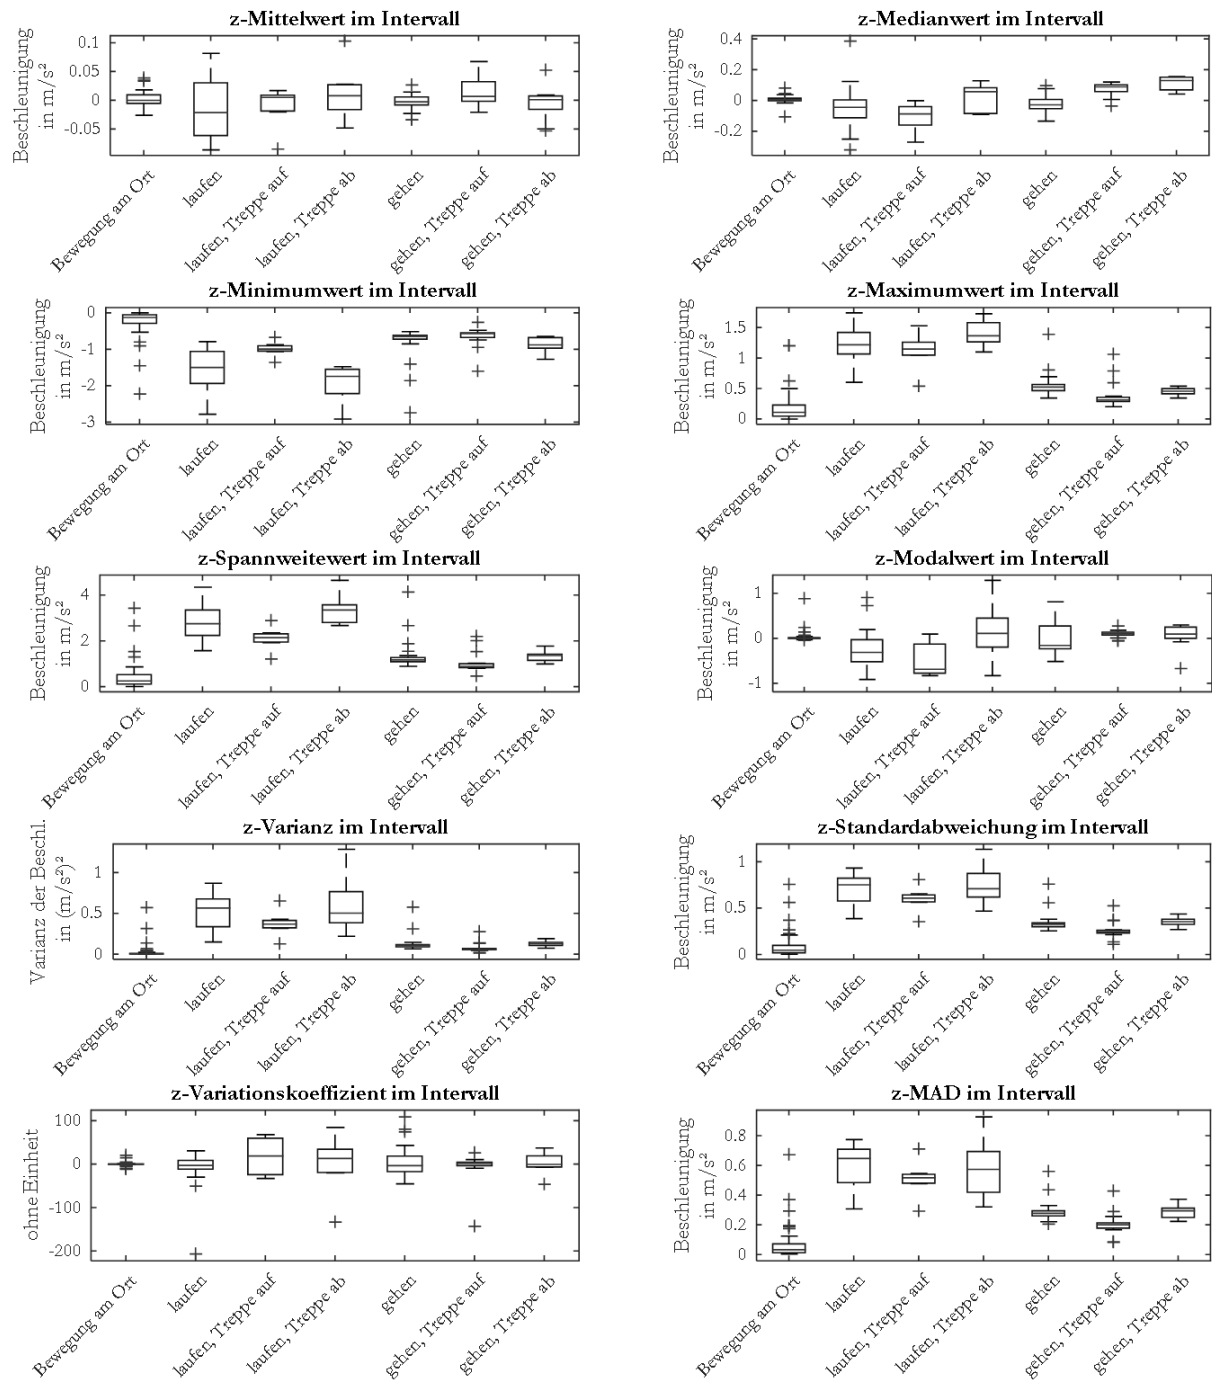


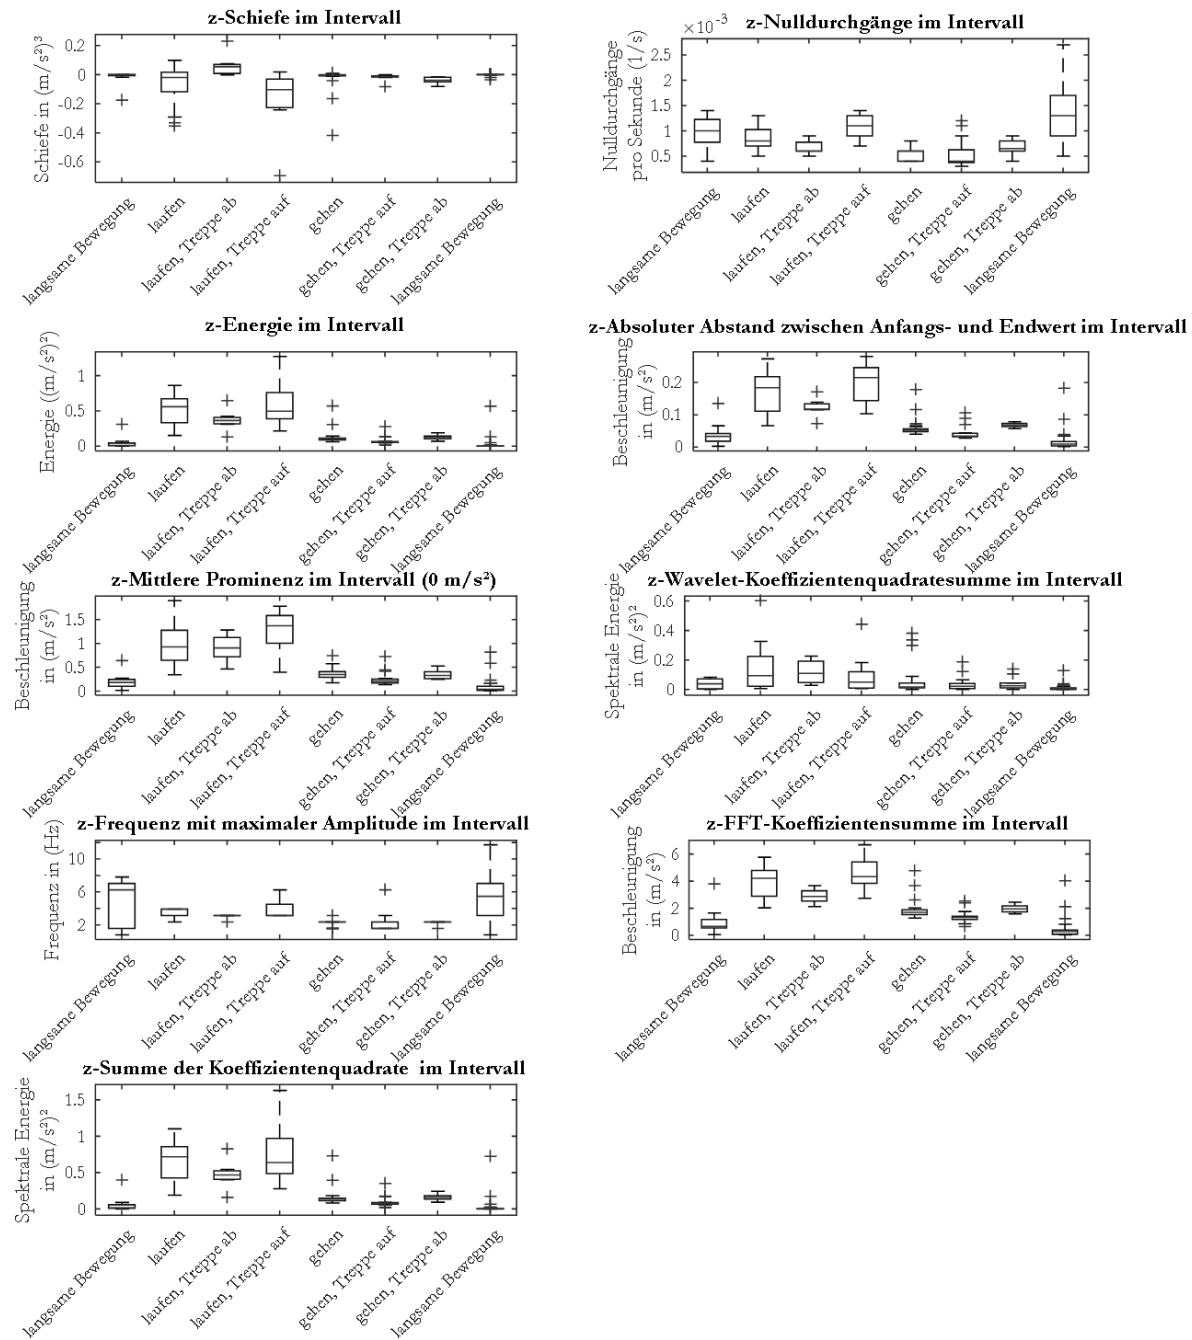
x-Wavelet-Koeffizientenquadratsumme im Intervall











Anhang H Boxplots zur Analyse des Bewegungsmodus auf Basis der deRFnode-Daten

